



Sveučilište u Zagrebu

AGRONOMSKI FAKULTET

Željka Bedek

# **STRATEŠKO UPRAVLJANJE RIZIKOM VINARIJA U HRVATSKOJ**

DOKTORSKI RAD

Zagreb, 2018.



University of Zagreb

FACULTY OF AGRICULTURE

Željka Bedek

# **STRATEGIC RISK MANAGEMENT OF WINERIES IN CROATIA**

DOCTORAL THESIS

Zagreb, 2018



Sveučilište u Zagrebu

AGRONOMSKI FAKULTET

ŽELJKA BEDEK

# **STRATEŠKO UPRAVLJANJE RIZIKOM VINARIJA U HRVATSKOJ**

DOKTORSKI RAD

Mentor:  
izv. prof. dr. sc. Mario Njavro

Zagreb, 2018.



University of Zagreb

FACULTY OF AGRICULTURE

Željka Bedek

# **STRATEGIC RISK MANAGEMENT OF WINERIES IN CROATIA**

DOCTORAL THESIS

Supervisor:  
Associate Professor Mario Njavro, PhD

Zagreb, 2018

Bibliografski podaci:

- Znanstveno područje: Biotehničke znanosti
- Znanstveno polje: Agronomija
- Znanstvena grana: Ekonomika poljoprivrede
- Institucija: Sveučilište u Zagrebu Agronomski fakultet
- Voditelj doktorskog rada: izv. prof. dr. sc. Mario Njavro
- Broj stranica: 158
- Broj slika: 13
- Broj tablica: 56
- Broj grafova: 22
- Broj priloga: 43
- Broj literaturnih referenci: 141
- Datum obrane doktorskog rada: 31. 01. 2018.
- Sastav povjerenstva za obranu doktorskog rada:
  - Doc. dr. sc. Vesna Očić, Sveučilište u Zagrebu Agronomski fakultet
  - Doc. dr. sc. Ana-Marija Jagatić Korenika, Sveučilište u Zagrebu Agronomski fakultet
  - Izv. prof. dr. sc. Jadranka Deže, Sveučilište Josipa Jurja Strossmayera u Osijeku Poljoprivredni fakultet u Osijeku

Rad je pohranjen u:

Nacionalnoj i sveučilišnoj knjižnici u Zagrebu, Ulica Hrvatske bratske zajednice 4  
p.p. 550, 10 000 Zagreb,  
Knjižnici Sveučilišta u Zagrebu Agronomskog Fakulteta, Svetošimunska cesta 25,  
10 000 Zagreb.

Tema rada prihvaćena je na sjednici Fakultetskog vijeća Agronomskog Fakulteta  
Sveučilišta u Zagrebu, održanoj dana 04. 06. 2013., te odobrena na sjednici  
Senata Sveučilišta u Zagrebu, održanoj dana 11. 07. 2013.

SVEUČILIŠTE U ZAGREBU

**AGRONOMSKI FAKULTET**

**IZJAVA O IZVORNOSTI**

Ja, **Željka Bedek**, izjavljujem da sam samostalno izradila doktorski rad pod naslovom:

**STRATEŠKO UPRAVLJANJE RIZIKOM VINARIJA U HRVATSKOJ**

Svojim potpisom jamčim:

- da sam jedina autorica ovog dokorskog rada;
- da je doktorski rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristila drugim izvorima osim onih koji su u njemu navedeni;
- da sam upoznata s odredbama Etičkog kodeksa Sveučilišta u Zagrebu (Čl. 19).

Zagreb, \_\_. \_\_. \_\_\_\_ . godine

---

Potpis doktorandice

Datum obrane doktorskog rada: 31. siječnja 2018.

Članovi Povjerenstva za obranu doktorskog rada:

Doc. dr. sc. Vesna Očić, \_\_\_\_\_

Doc. dr. sc. Ana-Marija Jagatić Korenika, \_\_\_\_\_

Izv. prof. dr. sc. Jadranka Deže, \_\_\_\_\_

## Informacije o mentoru

Izv. prof. dr. sc. Mario Njavro

Zavod za menadžment i ruralno poduzetništvo, Sveučilište u Zagrebu Agronomski fakultet.

Dr. sc. Mario Njavro rođen je u Požegi 1974. godine. Godine 1993. upisuje Sveučilište u Zagrebu Agronomski fakultet, smjer Poljoprivredna ekonomika, na kojem diplomira 1997. godine. Slijedeće godine zapošljava se na Agronomskom fakultetu u Zavodu za upravu poljoprivrednog gospodarstva na radnom mjestu mlađeg asistenta. Poslijediplomski studij iz Ekonomike poljoprivrede završava 2001. godine. Doktorski rad naslova „Mikroekonomska analiza strategija za upravljanje rizikom u proizvodnji jabuka“ iz područja ekonomike poljoprivrede obranio je 18. svibnja 2006. godine. Za uspjeh tijekom dodiplomskog studija nagrađen je Dekanovom nagradom (1996. godine), a za dostignuća u obrazovanju i znanosti nagradom Agronomskog fakulteta (2004.). Suradnik je u nastavi na više modula na preddiplomskim studijama Agronomskog fakulteta. Na diplomskom studiju koordinator je dva modula: Upravljanje rizikom u poljoprivredi i Strateški menadžment u agrobiznisu. U okviru preddiplomskog studija voditelj je modula Menadžment i poduzetništvo poljoprivrede. Na poslijediplomskom doktorskom studiju Poljoprivredne znanosti koordinator je modula Metode analize rizika u poljoprivredi. Objavio je 25 znanstvenih radova i sudjelovao na 14 domaćih i 16 međunarodnih skupova i kongresa. Pristupnik sudjeluje na više domaćih i međunarodnih znanstvenih projekata i suautor je većeg broja stručnih studija u poljoprivredi i agrobiznisu. Član je Hrvatskog agroekonomskog društva i Europskog udruženja agrarnih ekonomista (EAAE).

U razdoblju 2010. - 2015. obnašao je dužnost predstojnika Zavoda za menadžment i ruralno poduzetništvo. Od 2008. do 2014. godine bio je tajnik poslijediplomskog dokorskog studija Ekonomika poljoprivrede, a od 2011. do 2015. voditelj je poslijediplomskog specijalističkog studija Poslovno upravljanje u agrobiznisu MBA.

Dr. sc. Mario Njavro aktivno govori engleski jezik, pasivno poznaje španjolski jezik. Posjeduje napredna znanja rada na računalu.



## **Zahvala**

Zahvaljujem svojoj obitelji na razumijevanju, strpljenju, poticanju, veselju i jer su cijelo vrijeme bili uz mene. Hvala svim prijateljima na razumijevanju i ohrabrivanju.

Zahvaljujem mentoru, izv. prof. dr. sc. Mariju Njavri na velikoj pomoći u izradi doktorskog rada, ustrajnosti, razumijevanju, strpljivosti i savjetima. Hvala Vam.

Zahvaljujem prof. dr. sc. Mirjani Čižmešija na velikoj pomoći u izradi doktorskog rada.

Hvala kolegici i prijateljici dr. sc. Marini Tomić i Martini Malić na velikoj pomoći.

Hvala na savjetima, stručnim pojašnjenima i strpljenju svim kolegama Hrvatskog centra za poljoprivredu, hranu i selo. Hvala gđi Ivki Leljak iz Državnog zavoda za statistiku i gosp. Miri Mačinkoviću iz SRCE-a.

Najvažnija zahvala je, hvala Ti Gospodine Isuse!

## Sažetak

U vinogradarstvu i vinarstvu Republike Hrvatske sabrani su tradicija, žrtva i nada, jedinstvenost *terroira* i sortimenta. Osim ove gotovo „romantične“ slike, vinogradari i vinari izloženi su svakodnevnom dokazivanju na tržištu. Upravljanje rizicima važan je dio poslovnog uspjeha i potrebno im je posvetiti važnost i sagledati ih u cjelini.

Ciljevi istraživanja bili su analizirati rizik u poslovanju, rangirati vinarije prema stupnju rizika i dati preporuke instrumenata upravljanja rizikom te ustanoviti učinkovitost strateškog upravljanja rizikom primjenom stohastičkih simulacija.

U radu su korištene metode analize rizika, strateškog upravljanja, anketnog ispitivanja, regresijska, korelacijska i financijska analiza i stohastičke simulacije.

Rezultati su pokazali da anketirane vinarije u Hrvatskoj prepoznaju rizike i strategije, ali nedovoljno primjenjuju strategije upravljanja rizicima. Ispitanici smatraju važnim primjenjivati strategije za upravljanje rizicima na gospodarstvu (poput pridržavanja tehnologije i agrotehničkih rokova, prodaje putem više različitih kanala, ...) i izvan gospodarstva (poput korištenja programa potpore) te strategije prijenosa rizika (osiguranje,...). S druge strane, ispitanici ponekad i često primjenjuju strategije izvan gospodarstva i ponekad primjenjuju strategije za upravljanje rizicima na gospodarstvu. Strategije prijenosa rizika rijetko se primjenjuju u anketiranim vinarijama u Hrvatskoj.

Financijski pokazatelji sugeriraju da se većina vinarija, u promatranom petogodišnjem razdoblju, nalazi u teškoj situaciji u svom poslovanju što se tiče likvidnosti, zaduženosti i rizika od stečaja. Prema ukupnoj prosječnoj vrijednosti, 47 poslovnih subjekata od ukupno 95 poslovalo je s dobitkom.

Altman A-Z *score* kao pokazatelj rizika od stečaja primijenjen je za rangiranje vinarija prema stupnju rizika. Prema standardnoj devijaciji Altmanov A-Z-*score* rangirano je 95 vinarija u Hrvatskoj. Rezultati su pokazali veliki broj visoko rizičnih vinarija koje su imale prosječnu srednju vrijednost *score*-a manju od 1,23, a kojima prijeti vrlo veliki, 95%-tni rizik od stečaja. Od ukupno 95 analiziranih vinarija, 75 poslovnih subjekata visoko su rizične vinarije. Rezultati jednostavne linearne regresije pokazali su da je najrizičnija varijabla materijalni trošak koji utječe na ukupan prihod. Osim materijalnih troškova i troškovi osoblja imaju utjecaj na ukupan prihod. Rezultati modela strateškog upravljanja rizikom odnosno strategije modernizacije i rasta kroz nova ulaganja rezultirali su povećanjem stope rasta, Altman A-Z *score*-a, neto i bruto dobiti, dobiti prije kamata i poreza, povrata na imovinu, povrata na kapital za 7%, 23,74%, 59%, 41,35%, 36,06% i 22,56%. Istraživanjem je potvrđeno da su vinarije u Hrvatskoj izložene riziku i da primjena strateškog upravljanja rizikom doprinosi rastu i profitabilnosti vinarija.

Ključne riječi: strateško upravljanje, rizik, strategije, vinarije, Republika Hrvatska

## **Extended summary**

### **STRATEGIC RISK MANAGEMENT OF WINERIES IN CROATIA**

Viticulture and Enology as part of agriculture of the Republic of Croatia encompasses tradition, hard work, sacrifice, persistence and hope of vine and wine growers, uniqueness of terroir and vine varieties, and potential of wine placement through tourism. By EU accession, Croatian wine makers have entered the market of half a billion consumers. These are consumers of high purchasing power and, to a large extent, experts in the culture of consuming wine. However, there are threats that emerge from the inner weaknesses of the wineries, in the management, organization and financing of this threat from the environment, first of all competition. Therefore, one of the necessary preconditions of business success is strategic thinking and risk management. All of this has led us to research business subjects in the wine industry, the risks faced by winemakers, and the strategies they apply to successfully manage their business.

The objectives of the research were to analyze the risk in the winery business, to rank wineries according to the degree of risk and to give recommendations to risk management instruments and to identify the effectiveness of strategic risk management using stochastic simulations. The systematic risk management scenarios are developed in the model example.

The paper deals with methods of risk analysis, strategic management, questionnaire testing, regression, correlation and financial analysis and stochastic simulations. The research material consists of a primary survey (SWOT analysis of the state of the winery sector in the Republic of Croatia and a survey on risk management perceptions in Croatian wineries "Strategic Risk Management of Wineries in Croatia") and secondary data sources.

The risk management has been in the focus of research for many years and there are numerous risk management papers that observe it from different aspects, such as sources of risk and their impact on business, business decision making, risk management strategies, and farmers' preferences to risk. In the segment of strategic management, the authors deal specifically with the issue of competitiveness and the strategies of vertical integration of companies.

Every business is exposed to risks. Agricultural production is additionally burdened with the risks of natural disasters, disease and pests and environmental pollution. This survey evaluated the state of the sector and the conditions of the winery business, analyzed the risks faced by winemakers and the risk management they apply. Based on the existing

state of affairs and the calculation of key business indicators, a model was proposed with improvements for risk management. The results of the research have shown that the environment in which wineries operate in Croatia is very uncertain. On the other hand, providing quality and timely information to decision makers in executive and business entities can have a positive impact on the state of the vineyard sector in the Republic of Croatia.

Wineries in Croatia today act as part of the global market. The available data show a trend of decreasing vineyards (-3.04% in 2015/2005) and wine production (-1.29% in 2015/2005) in a world that has not bypassed wineries in Croatia. In 2015, compared to 2005, vineyards in Croatia decreased by -13.76%, grape production by -14.80% and wine production by -20.51%.

In the period from 2005 to 2015, wineries in the Republic of Croatia were exposed to significant temptations in their business: from climatic conditions, "poor" vine harvest (2015), the impact of the economic crisis (2008 to 2017), high prices (in 2009 the interest rate on loans in HRK without a currency clause of 9.69%), growth of average costs of raw materials consumption by unit of measure of all energy sources in the production of beverages (27.31% on average), changes in wine prices and the procedure of trade wine, the accession of the Republic of Croatia to the European Union and import of wine.

The importance of tourism in product placement (mean value 4.20), top position (mean value 4.12) and environmental conditions in grape and wine production (average 4.00) are evidenced by the experts in viticulture and winemaking. For sector weaknesses, surface saturation, wine growers' lack of organization and lack of marketing (mean value 4.20) are highlighted. New technologies (mean 2.00) and all forms of tourism (agrotourism, wine tourism, tourism demand) (mean 2.04) represent the potential for wineries in Croatia, affected by the "black market" risk and the lack of inspection (average 2.16) and competition (wines of the same quality, but lower prices) (mean value 2.20).

In identifying risks and strategies for wineries in Croatia, respondents perceive the relatively moderate risks they face. As risk consequences, 39.47% of respondents believe that natural disasters can have significant consequences for the company's business, 44.74% of respondents believe that biology and the environment can have significant consequences, 47.37% of respondents believe the market can have a moderate impact, 50.00% of respondents believe that management and processes have a moderate impact, while for political influence (52.63%), they consider it to have significant business implications. Respondents consider it important to apply strategies for managing the risks "on farm" (such as adhering to technology and agrotechnical deadlines, sales through

multiple channels, ...) and "off farm" (such as the use of support programs) and risk transfer strategies (insurance, ...). Respondents apply "off farm" strategies such as national and EU programs, production diversification and apply "on farm" strategies for managing the risks such as adhering to technology and agrotechnical terms, using their own land, selling products through multiple channels, continuous learning and information, human resources, procurement systems and logistics. Risk transfer strategies (insurance, sales contracts, contract with subcontractors, production for a known customer) are rarely applied in surveyed wineries in Croatia. Such thinking is expected, given the price of applying certain strategies (insurance prices, investments required in technology, education, ...).

The financial analysis of the winery business showed that from 2011 to 2015 the number of business entities increased by 20% (from 172 in 2011 to 207 business entities in 2015), but 95 business entities had available data in the observed period. According to the size of business entities, the largest number of entities is small entities (91), and by type of ownership, 76 business entities were privately owned. The results of the analysis have shown that small businesses are more liquid, less dependent in comparison to large or medium-sized businesses. In medium-sized enterprises, low profitability was noticed (return on assets ranged from -0.24 in 2011 to -0.15 in 2015, return on equity ranges from 0.15 in 2011 to 0.01 in 2015), and large and small companies are facing a very high risk of bankruptcy. According to legal form, joint stock companies have the lowest average values of current liquidity coefficients, rapid liquidity, financial stability, highest indebtedness coefficient and the lowest return on equity. The joint stock companies had a mean value of Altman A-Z score of -1.99, while agricultural cooperatives had a mean value of A-Z score of 2.07. According to Altman's A-Z-score, business entities are facing a very high risk, 95% risk of bankruptcy (an average of less than 1.23). According to the characteristics of business entities, the risk of bankruptcy is very high in 43 companies registered as a limited liability company, in 59 small enterprises, in 54 private ownership companies, in 56 companies with 100% domestic capital, in 26 enterprises with less than 10 employees and 38 companies in the area of coastal Croatia. One business entity, which is registered as limited company, belongs to small enterprises, which is privately owned since its inception, with a 100% share of domestic capital, excluding employees and from the coastal part of Republic of Croatia, was not involved in the processing.

The results of multiple regression models on the winery analysis ( $n = 95$ ) of total revenue (dependent variables) and number of employees, material costs, staff costs (independent variables) showed that dummy variables "county" and "domestic capital" are not statistically significant. Variables "legal status" and "winery size" are statistically significant

in the model. The regression of total revenue (dependent variable) and one independent variable and one dummy variable has shown that the “business status” and “size” are statistically significant variables. Dummy variables “counties” and “domestic capital” have not shown statistically significant. The results of simple linear regression have shown that material costs (standardized coefficient 0.94) have the greatest relative impact on total revenue.

According to the standard deviation, Altman's A-Z-score ranked 95 wineries in Croatia. For the period from 2011 to 2015, there were 8 business entities facing a very low risk of bankruptcy, 10 medium-risk wineries and 75 high-risk wineries, which confirms the difference between wineries in terms of the degree of financial risk. Two business entities are not involved in the processing.

The simulation of the model “Vinarija” has applied risk management strategies, a cost-cutting flexibility strategy that stabilizes the cost of wine-making, a market expansion strategy that assumes increased sales, i.e. greater capacity utilization, a sales stability strategy that is based on the assumption that the influence of the price of wine or its stabilization on the winery is coming the more favorable financial position and the strategy of modernization and growth through new investments starts from the assumption of new wage borrowing. The model is a stochastic simulation model created in @Risk software (Excel supplement) with Monte Carlo simulation and 5000 iterations. Stochastic input parameters are the sales price of wine, the cost of wine production (cost price) and winery capacity (% capacity utilization). The results of the model or strategy of modernization and growth through new investments resulted in an increase in the growth rate, Altman A-Z score, net and gross profit, profit before interest and tax, return on assets, return on equity by 7%, 23.74%, 59 %, 41.35%, 36.06%, and 22.56%.

The research has confirmed that wineries in Croatia are exposed to risk and that the application of strategic risk management contributes to the growth and profitability of wineries.

Key words: risk, strategy, strategic management, wineries, the Republic of Croatia

## Sadržaj

1. UVOD .....	1
1.1. Strateško upravljanje .....	2
1.2. Strateško upravljanje rizicima u poljoprivredi .....	2
2. HIPOTEZE I CILJEVI ISTRAŽIVANJA .....	4
3. PREGLED DOSADAŠNJIH ISTRAŽIVANJA .....	4
4. MATERIJAL I METODE RADA .....	10
4.1. Materijal .....	10
4.2. Metode rada .....	12
4.2.1. Metode analize rizika .....	12
4.2.2. Regresijska i korelacijska analiza .....	16
4.2.3. Stohastičke simulacije .....	19
4.2.4. Metode strateškog upravljanja .....	21
4.2.5. Anketno ispitivanje .....	22
4.2.6. Financijska analiza .....	29
5. REZULTATI ISTRAŽIVANJA .....	33
5.1. Obilježja proizvodnje i tržišta grožđa i vina .....	33
5.1.1. Percepcija poslovnog okruženja vinarija u Hrvatskoj .....	44
5.2. Analiza rizika vinarija u Hrvatskoj .....	48
5.2.1. Identifikacija rizika i strategija u vinarijama .....	48
5.2.2. Rizici u vinarstvu .....	67
5.2.3. Analiza poslovanja i financijski rizici vinarija .....	73
5.2.4. Rangiranje vinarija prema stupnju rizika .....	88
5.3. Strateško upravljanje rizikom .....	90
5.3.1. Model strateškog upravljanja rizikom .....	90
5.3.2. Scenarijska analiza strategija za upravljanje rizikom .....	94
6. RASPRAVA .....	101
6.1. Strateško upravljanje i rizici u vinarijama .....	103
6.2. Izloženost vinarija riziku .....	104

6.3.	Rangiranje vinarija prema stupnju rizika .....	108
6.4.	Strateško upravljanje rizikom .....	108
7.	ZAKLJUČCI .....	110
8.	POPIS LITERATURE.....	113
9.	ŽIVOTOPIS .....	125
10.	PRILOZI .....	126



## Popis kratica

AIRMIC – *Association of Insurance and Risk Managers in Industry and Commerce*

ALARM – *The National Forum for Risk Management in the Public Sector*

AAZS – Altman A-Z-score

AAZS-G – Altman A-Z-score - rast

BDP – Bruto domaći proizvod

BN – bilijuna

BZ – broj zaposlenih

CEFTA – *Central European Free Trade Agreement*

CFaR – eng. *Cash flow-at-Risk* (novčani tok pri riziku)

COGEA S.R.L. – *Consulenti per la gestione aziendale*

C.R. – kritični omjer

d.d. – dioničko društvo

DK – domaći kapital

D/A – koeficijent zaduženosti

D/E – odnos duga i kapitala

d.o.o. – društvo ograničene odgovornosti

EaR – eng. *Earning at risk* (kretanje dohotka pri riziku)

EBITDA – dobit prije kamata

EBIT – dobit prije kamata i poreza

ERM – eng. *Enterprise Risk Model* (model upravljanja rizikom poduzeća)

EU – Europska unija

EUR – Euro

EUR/l – Euro/litra

FINA – Financijska agencija

Fin. stab. – financijska stabilnost

G – eng. *growth* (rast)

GJ – gigajoul

ha – hektar

HACCP – *The Hazard Analysis and Critical Control Points System*

HAMAG-BICRO – Hrvatska agencija za malo gospodarstvo i investicije

HBOR – Hrvatska banka za obnovu i razvitak

hl – hektolitar

HRK – Hrvatska kuna

HRK/l – Hrvatska kuna/litra

HRK/KG – Hrvatska kuna/kilogram

IRM – *The Institute of Risk Management*  
IRR – interna stopa rentabilnosti  
IT – eng. *information technology* (informacijske tehnologije)  
j.d.o.o. – jednostavno društvo ograničene odgovornosti  
kha – tisuća hektara  
Mhl – milijuna hektolitara  
KZP – kontrolirano zemljopisno podrijetlo  
Likv. – likvidnost  
MT – materijalni troškovi  
MWh – megavat sat  
N – broj  
NPV – neto sadašnje vrijednosti  
NKD – Nacionalna klasifikacija djelatnosti  
OIV – *International Organisation of Vine and Wine*  
OPG – obiteljsko poljoprivredno gospodarstvo  
PDV – porez na dodanu vrijednost  
Poduz. – poduzetnik  
Poslj. – posljedica  
PS – pravni status  
PR – poslovni rashod  
P.Z. – poljoprivredna zadruga  
R – koeficijent korelacije  
RH – Republika Hrvatska  
ROA – povrat na imovinu  
ROE – povrat na kapital  
SAD – Sjedinjene Američke Države  
t/ha – tona/hektar  
tis. hl – tisuća hektolitara  
tis. HRK – tisuća kuna  
tis.m<sup>3</sup> – tisuću metara kubnih  
TO – trošak osoblja  
UP – ukupan prihod  
UR – ukupni rashod  
V – veličina  
Vjeroj. – vjerojatnost  
ZOI – zaštićena oznaka izvornosti  
Ž – županija

## Popis tablica

Tablica 1: Prikaz broja odaslanih anketa prema županijama.....	11
Tablica 2: Vinogradarske površine, proizvodnja, potrošnja i trgovina vina u svijetu.....	33
Tablica 3: Vodeće zemlje Europe u proizvodnji vina (1.000 hl) .....	34
Tablica 4: Broj poduzeća prema proizvodnji vina od grožđa.....	35
Tablica 5: Vrijednost proizvodnje vina od grožđa (milijuni EUR).....	35
Tablica 6: Cjenovni razredi vina (pakovine 0,75 l, EUR/l) .....	35
Tablica 7: Površine poljoprivrednog zemljišta, vinograda, proizvodnja grožđa, vina i prinos u Republici Hrvatskoj .....	37
Tablica 8: Promet vina prema kategorijama kakvoće u Republici Hrvatskoj (hl) .....	38
Tablica 9: Izvoz vina iz Republike Hrvatske prema količini i vrijednosti .....	38
Tablica 10: Uvoz vina u Republiku Hrvatsku prema količini i vrijednosti .....	39
Tablica 11: Godišnji strukturno-poslovni pokazatelji poduzeća prema NKD-u 2007. za djelatnosti industrije, proizvodnju vina od grožđa u Republici Hrvatskoj .....	40
Tablica 12: Struktura gospodarskih subjekata prema vrsti pravno-organizacijskog oblika subjekta i broju vinogradarskih parcela u Republici Hrvatskoj .....	41
Tablica 13: Proizvedene, prodane količine, vrijednost i cijena mirnih, specijalnih, pjenušavih vina i mošta u RH.....	42
Tablica 14: Prosječne proizvođačke cijene vina i grožđa u RH iz vlastite proizvodnje .....	42
Tablica 15: Obilježja ispitanika prema dobi, spolu, obrazovanju i vrsti poslovnog subjekta .....	49
Tablica 16: Struktura ispitanika prema županijama .....	49
Tablica 17: Radno mjesto ispitanika, neovisno o broju „uloga“ unutar poslovnog subjekta (n = 38) .....	50
Tablica 18: Vjerojatnosti i posljedica rizika prema grupama rizika .....	52
Tablica 19: Grupa rizika biologija i okoliš prema pojedinačnim rizicima (n = 38) .....	52
Tablica 20: Grupa rizika tržište prema pojedinačnim rizicima (n = 38).....	53
Tablica 21: Grupa rizika upravljanje i procesi prema pojedinačnim rizicima (n = 38) .....	54
Tablica 22: Grupa rizika politika i institucije prema pojedinačnim rizicima (n = 38) .....	55
Tablica 23: Rangiranje očekivanih gubitka prema grupama rizika (n = 38).....	56
Tablica 24: Rangiranje očekivanih gubitka prema pojedinačnim rizicima (n = 38) .....	56
Tablica 25: Rangiranje očekivanih gubitka prema rizicima (n = 38).....	59
Tablica 26: Očekivanja ispitanika o utjecaju grupa rizika na poslovanje, u petogodišnjem razdoblju (n = 38).....	60
Tablica 27: Važnost i učestalost primjene strategija za upravljanje rizicima u poslovanju prema grupama rizika i broju ispitanika.....	60

Tablica 28: Strategije za upravljanje rizicima izvan gospodarstva (n = 38) .....	61
Tablica 29: Strategije za upravljanje rizicima na gospodarstvu (n = 38) .....	61
Tablica 30: Strategije za upravljanje rizicima prijenosom rizika (n = 38) .....	62
Tablica 31: Razlozi zbog kojih ispitanici učestalije ne koriste strategije upravljanja rizicima u poslovanju (n = 38) .....	63
Tablica 32: Pouzdanost rezultata provedenog istraživanja.....	63
Tablica 33: Korelacija grupa rizika vjerojatnosti nastanka rizika i posljedica rizika (n = 38) .....	65
Tablica 34: Korelacija grupa strategija važnosti primjene strategija i učestalosti primjene strategija (n = 38).....	66
Tablica 35: Udio kategorija kakvoće vina u prometu vina Republike Hrvatske (%).....	70
Tablica 36: Broj poslovnih subjekata s dostupnim podacima u FINA-i.....	73
Tablica 37: Poslovni subjekti prema županijama.....	74
Tablica 38: Poslovni subjekti prema veličini poduzetnika .....	74
Tablica 39: Poslovni subjekti prema vlasništvu .....	75
Tablica 40: Poslovni subjekti prema udjelu domaćeg kapitala.....	75
Tablica 41: Poslovni subjekti prema broju zaposlenih .....	75
Tablica 42: Poslovni subjekti prema pravnom statusu naznačenom u nazivu subjekta ....	76
Tablica 43: Odabrane stavke bilance za razdoblje od 2011. do 2015. (srednja vrijednost, .....	77
Tablica 44: Financijski pokazatelji poslovnih subjekata prema veličini za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	79
Tablica 45: Financijski pokazatelji poslovnih subjekata prema nazivu za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	80
Tablica 46: Poslovni subjekti prema obilježju poslovanja i vrijednostima Altmanovog A-Z-score-a (srednja vrijednost, n = 95 poslovnih subjekata).....	81
Tablica 47: Regresija ukupnog prihoda (zavisne varijable) i nezavisnih varijabli (n = 95).83	
Tablica 48: Regresija ukupnog prihoda (zavisne varijable) i nezavisnih varijabli (n = 95).85	
Tablica 49: Regresija ukupnog prihoda (zavisne varijable) i nezavisnih varijabli (n = 95).86	
Tablica 50: Procijenjeni parametri u regresijskom modelu sa standardiziranim varijablama jednostavne linearne regresije .....	88
Tablica 51: Vrijednosti odabranih pozicija bilance i računa dobiti i gubitka „Vinarije“, prosjek za razdoblje od 2011. do 2015. ....	91
Tablica 52: Rezultati poslovanja vinarije (statički pod model), prosjek za razdoblje od 2011. do 2015.....	91
Tablica 53: Stohastički elementi podmodela „Vinarije“ .....	92
Tablica 54: Rezultati stohastičkog modela, prosjek za razdoblje od 2011.do 2015. ....	92

Tablica 55: Prikaz strategije modernizacije i rasta i usporedba s primjenom stohastičkog podmodela „Vinarije“ .....	97
Tablica 56: Učinak strategije modernizacije i rasta na financijske pokazatelje .....	98

## Popis grafova

Graf 1: Ukupna potrošnja vina po stanovniku.....	34
Graf 2: Struktura ispitanika (n = 25) .....	44
Graf 3: Snage i slabosti vinarija i vinarstva u RH (n = 25) .....	46
Graf 4: Prilike i prijetnje vinarija i vinarstva u RH (n = 25).....	46
Graf 5: Provođenje aktivnosti/projekata unutar tvrtke prema broju ispitanika (n = 38) .....	50
Graf 6: Upravljanje rizicima prema broju ispitanika (n = 38) .....	51
Graf 7: Ukupni prihodi i rashodi te dobit ili gubitak za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	77
Graf 8: Financijski pokazatelji poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	79
Graf 9: ROA i ROE poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	79
Graf 10: Altmanov A-Z-score poslovnih subjekata (srednja vrijednost, n = 95 poslovnih subjekata) za razdoblje od 2011. do 2015.....	80
Graf 11: Vinarije u Hrvatskoj prema rizičnosti (standardna devijacija 2011. - 2015., n = 95 poslovnih subjekata) .....	89
Graf 12: Neto dobit stohastičkog modela „Vinarije“ .....	92
Graf 13: ROA i ROE stohastičkog modela „Vinarije“ .....	93
Graf 14: Altman A-Z-score stohastičkog modela „Vinarije“ .....	93
Graf 15: Prikaz kretanja neto dobiti uz primjenu strategije troškovne fleksibilnosti .....	94
Graf 16: Prikaz kretanja ROA uz primjenu strategije širenja na tržištu .....	95
Graf 17: Prikaz kretanja ROE uz primjenu strategije stabilnosti prodaje.....	96
Graf 18: Prikaz kretanja Altman A-Z-score uz primjenu strategija .....	96
Graf 19: Kretanje neto dobiti primjenom strategije modernizacije i rasta kroz nova ulaganja .....	99
Graf 20: Kretanje EBIT primjenom strategije modernizacije i rasta kroz nova ulaganja ....	99
Graf 21: Kretanje Altman A-Z-score-a primjenom strategije modernizacije i rasta kroz nova ulaganja.....	100
Graf 22: Kretanje stope rasta primjenom strategije modernizacije i rasta kroz nova ulaganja.....	100

## Popis slika

Slika 1: Upravljanje rizikom poduzeća.....	3
Slika 2: Rangiranje očekivanih gubitaka (vjerojatnost x snaga) .....	14
Slika 3: Stablo odlučivanja .....	15
Slika 4: Ciklus analize odlučivanja .....	20
Slika 5: Strukturalni model za uvođenje novog proizvoda .....	21
Slika 6: SWOT analiza .....	21
Slika 7: Model Porterovih pet sila .....	22
Slika 8: Promjena prinosa i količina proizvodnje u razdoblju od 2005. do 2015. godine ...	67
Slika 9: Prosječna cijena potrošnje u propisanoj mjernoj jedinici energenta u proizvodnji pića za razdoblje od 2005. do 2015. godine .....	69
Slika 10: Promjena kamatnih stopa i srednjeg tečaja eura u razdoblju od 2005. do 2015. ....	71
Slika 11: Razina zaduženosti, ROA, ROE i Altmanov A-Z-score u razdoblju od 2011. do 2015. (srednja vrijednost) .....	82
Slika 12: Ciklus analize odlučivanja, temeljem analize ankete „Strateško upravljanje rizikom vinarija u Hrvatskoj“, prilagođeno iz Njavro (2017) .....	90
Slika 13: Stablo odlučivanja bez primjene i s primjenom strateškog upravljanja rizikom...	98

## Popis priloga

Prilog 1: Anketa „Analiza stanja vinarskog sektora u Republici Hrvatskoj“ .....	126
Prilog 2: Izvori literature u anketi „Strateško upravljanje rizikom vinarija u Hrvatskoj“ .....	129
Prilog 3: Proizvodi industrijske proizvodnje (sumarna tabela proizvodnje zbrojena za vlastiti račun i na osnovi ugovora) za vino, mirna vina, specijalna vina, pjenušava vina i mošt.....	132
Prilog 4: Konačne zalihe vodećih zemalja u Europi (1.000 hl) .....	135
Prilog 5: Ukupna domaća potrošnja vodećih zemalja u Europi (1.000 hl) .....	135
Prilog 6: Stupanj samodostatnosti (%) .....	135
Prilog 7: Ukupna potrošnja vina po stanovniku (l/po stanovniku).....	135
Prilog 8: Bilanca vina u 000 hl.....	136
Prilog 9: Snage vinarija i vinarstva Republike Hrvatske.....	137
Prilog 10: Slabosti vinarija i vinarstva Republike Hrvatske .....	138
Prilog 11: Prilike za vinarije i vinarstvo Republike Hrvatske.....	139
Prilog 12: Prijetnje vinarijama i vinarstvu Republike Hrvatske .....	140
Prilog 13: Usporedba srednje vrijednosti (Mean) i 5% Trimmed Mean vrijednosti snaga, slabosti, prilika i prijetnji vinarijama i vinarstvu (n = 25) .....	141

Prilog 14: I dio tablice korelacije (Pearsonovog koeficijenta korelacije) snaga i slabosti vinarija i vinarstva RH (n = 25) .....	144
Prilog 15: II dio tablice korelacije (Pearsonovog koeficijenta korelacije) snaga i slabosti vinarija i vinarstva RH (n = 25) .....	145
Prilog 16: I dio tablice korelacije (Pearsonovog koeficijenta korelacije) prilika i prijetnji vinarijama i vinarstvu RH (n = 25) .....	146
Prilog 17: II dio tablice korelacije (Pearsonovog koeficijenta korelacije) prilika i prijetnji vinarijama i vinarstvu RH (n = 25) .....	147
Prilog 18: Koeficijent tekuće likvidnosti malih i srednje velikih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	148
Prilog 19: Koeficijent ubrzane likvidnosti malih i srednje velikih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	148
Prilog 20: Koeficijent financijske stabilnosti malih i srednje velikih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	148
Prilog 21: Razina zaduženosti malih i srednje velikih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	149
Prilog 22: ROA i ROE malih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 91 poslovnih subjekata) .....	149
Prilog 23: ROA i ROE srednje velikih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 4 poslovnih subjekata) .....	149
Prilog 24: Altmanov A-Z-score srednje velikih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	150
Prilog 25: Koeficijent tekuće likvidnosti poslovnih subjekata prema pravnom statusu za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	150
Prilog 26: Koeficijent ubrzane likvidnosti prema pravnom statusu poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	150
Prilog 27: Koeficijent financijske stabilnosti prema pravnom statusu poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	151
Prilog 28: Razina zaduženosti prema pravnom statusu poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata) .....	151
Prilog 29: ROA i ROE dioničkih društava za razdoblje od 2011. do 2015. (srednja vrijednost, n = 7 poslovnih subjekata) .....	151
Prilog 30: ROA i ROE društava ograničene odgovornosti za razdoblje od 2011. do 2015. (srednja vrijednost, n = 61 poslovnih subjekata) .....	152
Prilog 31: ROA i ROE poljoprivrednih zadruga za razdoblje od 2011. do 2015. (srednja vrijednost, n = 17 poslovnih subjekata) .....	152

Prilog 32: Altmanov A-Z-score modela prema pravnom statusu poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata).....	152
Prilog 33: Relativni utjecaj triju nezavisnih varijabli na ukupni prihod model višestruke regresije sa standardiziranim varijablama .....	153
Prilog 34: Relativni utjecaj triju nezavisnih varijabli na ukupni prihod model višestruke regresije sa standardiziranim varijablama .....	153
Prilog 35: Relativni utjecaj triju nezavisnih varijabli na ukupni prihod model višestruke regresije sa standardiziranim varijablama .....	154
Prilog 36: Regresija ukupnog prihoda (zavisne varijable) i broja zaposlenih i pravnog statusa .....	154
Prilog 37: Relativni utjecaj broja zaposlenih i pravnog statusa na ukupni prihod .....	155
Prilog 38: Regresija ukupnog prihoda (zavisne varijable) i broja zaposlenih i veličine ....	155
Prilog 39: Relativni utjecaj broja zaposlenih i veličine na ukupni prihod .....	156
Prilog 40: Regresija ukupnog prihoda (zavisne varijable) i ukupnih rashoda i pravnog statusa .....	156
Prilog 41: Relativni utjecaj ukupnih rashoda i pravnog statusa na ukupni prihod.....	157
Prilog 42: Regresija ukupnog prihoda (zavisne varijable) i ukupnih rashoda i veličine....	157
Prilog 43: Relativni utjecaj ukupnih rashoda i veličine na ukupni prihod .....	158



# 1. UVOD

Vinogradarstvo i vinarstvo u poljoprivredi Republike Hrvatske sabire tradiciju, težački rad, žrtvu, upornost i nadu vinogradara i vinara te jedinstvenost terroira i sortimenta. Osim ove gotovo „romantične“ slike, vinogradari i vinari izloženi su svakodnevnom dokazivanju na izrazito konkurentnom domaćem i stranom tržištu.

Ulaskom u Europsku uniju hrvatski su vinari dobili „ulaz“ na tržište od oko pola milijarde potrošača. To su potrošači visoke kupovne moći i, u velikom dijelu, poznavatelji kulture ispijanja vina. Pozitivni trendovi u turizmu, rast broja turista i noćenja u 2015. u odnosu na 2010. godinu predstavljaju priliku za snažnije marketinško djelovanje i u prodaji vina (Ministarstvo turizma, 2016). S druge strane, ulazak u EU otvorio je i hrvatsko tržište za vina iz velikih „vinskih zemalja“. Nakon ulaska u EU, „otvaranjem“ tržišta hrvatskim je potrošačima dostupan veći izbor vina, posebno uvoznih, po nižim cijenama.

Globalno i europsko tržište zahtijeva dobru organiziranost, trajnu kvalitetu, izvornost, dostatne količine i konkurentnost u cijenama. Kako bi prekoračili europski vinogradarski prag nužne su složenije, snažnije i brže akcije struke, politike i administracije da se utre put na oživotvorenju već donesenih programa (Skočić i Mihaljević, 2005). Postojeći institucionalni okvir omogućuje mjerama potpore korištenje sredstava za tržišnu potporu putem vinske omotnice te sufinanciranje osiguranja iz Programa ruralnog razvoja Republike Hrvatske za razdoblje 2014. – 2020. Posebnu dodatnu vrijednost u marketingu vina predstavljaju ekološki uzgoj, bogatstvo sortimenta te rast u kvaliteti, u korist vrhunskih vina. Da bi se odgovorilo zahtjevima tržišta i u pogledu kvalitete i količine potrebna su i značajna ulaganja.

U tom procjepu između ograničenja u agrarnoj strukturi, bogatstvu agroekoloških uvjeta i sortimenta, mogućnostima koje pruža svjetsko i EU tržište, i napokon i turizam, nužno je strateški promišljati i upravljati poslovnim subjektima u vinarstvu. Brojnim rizicima koji izviru u opisanoj situaciji, potrebno je posvetiti važnost. Strateško upravljanje rizikom trebalo bi predstavljati neizostavan dio strateškog menadžmenta vinarija. Preuzimanje rizika preduvjet je poslovnog uspjeha i profit možemo smatrati kao povrat na preuzeti rizik (Njavro i sur., 2005).

Poseban izazov u upravljanju rizicima ima vrijeme i pravovremeno uočavanje i prepoznavanje rizika te priprema mogućeg „odgovora“ na rizik. Usprkos svim prirodnim preduvjetima vinari i vinogradari teško se snalaze u novonastaloj situaciji.

Strateško upravljanje i strateško upravljanje rizikom stabilizira poslovanje, omogućava ulaganja te doprinosi rastu i razvoju poslovnog subjekta.

Sve navedeno, navelo nas je na istraživanje poslovnih subjekata u vinarstvu, rizika s kojima se vinarije suočavaju te strategija koje primjenjuju kako bi uspješno upravljale poslovanjem.

## 1.1. Strateško upravljanje

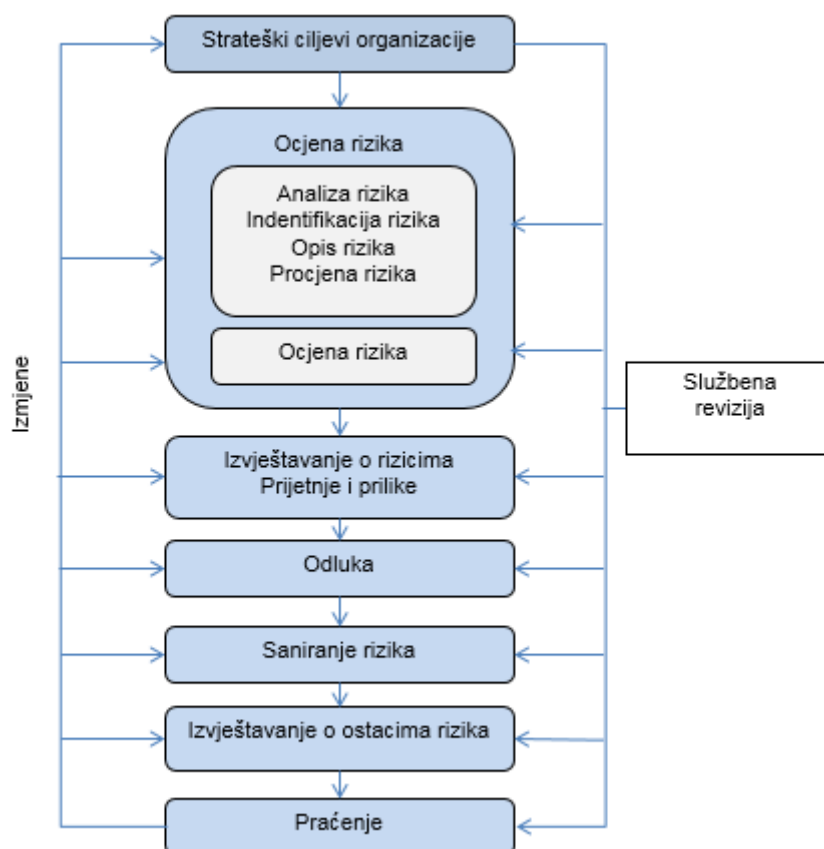
Strategija na sustavan način daje oblik i smjer poduzetničkom djelovanju o elementima poslovanja koji su svakom poduzetniku dobro poznati. Prema Bubleu (2000), prvi autor koji se bavio strategijom bio je Alfred D. Chandler, Jr. (1963), a definirao je strategiju kao „određivanje temeljnih dugoročnih ciljeva poduzeća, prilagođavanje smjerova poslovnih aktivnosti, odnosno određivanje koncepcija i izbor resursa potrebnih za postizavanje zacrtanih ciljeva“. Formulacija strategije uključuje razvoj vizije i misije, identificiranje vanjskih prilika i prijetnji organizacije, određivanje unutarnjih snaga i slabosti, uspostavu dugoročnih ciljeva, stvaranje alternativnih strategija, i odabir određene strategije koju se slijedi (David, 2011). Upravljanje rizikom središnji je dio strateškog upravljanja bilo kojeg poduzeća (AIRMIC, ALARM, IRM, 2002).

## 1.2. Strateško upravljanje rizicima u poljoprivredi

Budućnost donosi rizik... (Richardson i sur., 1997).

Rizici u poslovanju predstavljaju mogućnost događaja, najčešće negativnog, koji se još nije dogodio i za koji nismo u potpunosti sigurni hoće li se dogoditi.

Upravljanje rizikom poduzeća predstavlja okvir za analizu i suočavanje s rizicima, te praksu koju menadžeri široko prihvaćaju (Obuchowski, 2006), a definira se kao sustavna primjena menadžerskih politika, procedura i prakse s ciljem identifikacije, analize, procjene, pristupa i nadzora rizika (Hardaker i sur., 2004). Strateško upravljanje rizikom omogućuje poduzećima povećanje svog potencijala rasta, a kao dodatak, smanjuje njihove ekonomske nestabilnosti. Umjesto da se samo „brane“ od loših rizičnih događaja, vodeća poduzeća definiraju i predviđaju moguće željene rezultate rizika (Asfaw i Lipper, 2016) koji, ako se njima dobro upravlja, mogu rezultirati maksimalnim dobitkom (Slywotzky, 2005). Prema AIRMIC, ALARM, IRM (2002) upravljanje rizikom obuhvaća definiranje strateških ciljeva poduzeća, ocjenu rizika, izvještavanje, odlučivanje, saniranje rizika, izvještavanje i praćenje (slika 1).



Slika 1: Upravljanje rizikom poduzeća

Izvor: AIRMIC, ALARM, IRM (2002)

Izvore rizika u poljoprivredi Hardaker i sur. (2002) dijele na poslovne i financijske. Richardson i sur. (1997) razlikuju rizike poljoprivrednika i rizike poljoprivrednih gospodarstava. Rizike poljoprivrednika čine prinosi, cijena *inputa*, cijena *outputa*, kamatna stopa, poljoprivredna politika. Rizici poljoprivrednih gospodarstava su tržišni udio, troškovi prodaje proizvoda, cijena prodanih proizvoda, međunarodna tržišta i politika, kamatne stope i stope inflacije.

Poljoprivredna gospodarstva i poduzeća u suočavanju s rizicima primjenjuju različite strategije. Strategije se među ostalim mogu podijeliti u osnovne skupine, strategije koje se provode na samom gospodarstvu i izvan gospodarstva, strategije koje se provode prije samog nastanka rizičnog događaja te strategije koje ublažavaju posljedice nastanka pojedinih rizika (Anderson, 2001 iz The World Bank, 2005; Townsend, 2005 iz the World Bank, 2005; Meuwissenn i sur., 2001). Najbolja metoda za upravljanje rizicima ovisi o vrsti rizika. Moguće je razlikovati četiri različita protokola za upravljanje rizikom ovisno o trenutku djelovanja na rizik: izbjegavanje, smanjenje, preuzimanje i transfer rizika (Miller i sur., 2004, Sheehan, 2010).

## 2. HIPOTEZE I CILJEVI ISTRAŽIVANJA

Hipoteze istraživanja su:

- H1: Primjena strateškog upravljanja rizikom preduvjet je rasta i profitabilnih vinarija.
- H2: Vinarije se značajno razlikuju u izloženosti riziku (visoko, srednje i niskorizične).

Ciljevi istraživanja su:

- analizirati rizik u poslovanju vinarija, rangirati vinarije prema stupnju rizika i dati preporuke instrumenata upravljanja rizikom,
- ustanoviti učinkovitost strateškog upravljanja rizikom primjenom stohastičkih simulacija u scenarije poslovnog razvoja na primjeru modela.

## 3. PREGLED DOSADAŠNJIH ISTRAŽIVANJA

Područje upravljanja rizikom dugi je niz godina u fokusu istraživanja te postoje brojni radovi koji upravljanje rizikom sagledavaju s različitih aspekata, izvora rizika i njihovog utjecaja na poslovanje, poslovnog odlučivanja, strategija za upravljanje rizikom i sklonosti poljoprivrednika ka riziku. U segmentu strateškog menadžmenta autori se posebno bave problematikom konkurentnosti i strategijama vertikalne integracije poduzeća. Pregled literature oblikovan je tako da obuhvati istraživanja bliska temi doktorskog rada.

Wysocki i sur. (2003) testiraju okvir za odabir strategije vertikalne koordinacije proizvođača u dva poljoprivredna podsektora, proizvodnje sjemenskog krumpira i celera, države Michigan, SAD. Rezultati analize pokazali su da najnegativniji utjecaj na spremnost usvajanja nove, alternativne strategije imaju nesigurnost, potencijal ograničenja rasta profita, pozitivni rezultati primjene trenutne strategije, percepcija veličine promjene koju je potrebno napraviti da bi se promijenila strategija, proizvodna površina u najmu, broj članova upravljačkog tima, razlika u otkriću koordinacijskih sposobnosti proizvođača i mogućnosti za povećanje primjenom alternativne strategije, poslovno-profesionalno iskustvo donositelja odluka ili duljina poslovanja poduzeća.

Orr (1999) istražuje identificiranje uloge kvalitete u strateškom odlučivanju o proizvodnji u industriji vina Australije. Istraživanje je pokazalo da je kvaliteta najvažniji konkurentski prioritet za vinare, nakon čega slijede proizvodni troškovi.

Izazov za poljoprivredni sektor jest omogućiti poljoprivrednicima razvijanje njihovih strateških, marketinških i poduzetničkih vještina te je u tom smislu potrebna ekonomska potpora i veći naglasak na obrazovanje i osposobljavanje (McElwee i sur., 2006; Vesala i sur., 2007). Tome u prilog ide i istraživanje Charters i sur. (2008), koji su utvrdili da su menadžerske vještine u industriji vina ograničene te da se većina menadžera više fokusira na tehničko-tehnološku stručnost u odnosu na financijsku, stratešku, marketinšku, upravljačku ili vještine upravljanja ljudskim resursima.

Problem s kojim se suočavaju ispitanici istraživanja Inderheesa i Theuvsena (2009) jest kako se pozicionirati u odnosu na ekonomsko i političko okružje. U istraživanju većina ispitanika bavi se stočarskom proizvodnjom. Rezultati pokazuju da ispitanici u svom poslovanju primjenjuju široki spektar strategija, korporativne, konkurentske, funkcionalne i zadružne strategije.

Zanimljiva je i percepcija francuskih vinara regije Languedoc-Roussillon glede utjecaja krize i usvajanja strategija poduzeća. U istraživanju Duquesnois i sur. (2010) većina ispitanika preferira kombinaciju dviju strategija, odabir tržišne niše i diferencijaciju proizvoda. Istraživanjem je utvrđeno da značajan utjecaj na odabir strategije poduzeća ima prethodno iskustvo ispitanika.

Declerk (2005) je uspostavio tipologiju strategija vezanih za distribucijske kanale proizvođača šampanjca ("Maisons de Champagne"). Prema autoru operativna dobit proizvođača šampanjca ovisi o razvijenosti njihove distributivne mreže, a ona utječe na prodajnu cijenu. Strateška pitanja u vođenju vinarija obrađuju pojedine studije slučaja u SAD-u (Porter i Bond, 2006), Australiji (Porter i Solvell, 2003) i Francuskoj (Deighton i sur., 2007).

Mazzarol i sur. (2013) ispitali su u studiji slučaja australskih i francuskih proizvođačkih zadruga kako mala poduzeća koriste zadruge za strateško povezivanje. Da bi se osigurala održivost tih zadruga, potrebno je imati učinkovitu upravljačku mrežu, biti prilagodljiv i imati visoku razinu povjerenja i odanosti među članicama.

U Hrvatskoj, rezultati analize Mikić (2009) pokazuju da većina malih i srednjih proizvodnih poduzeća ne provodi strateško upravljanje troškovima već koristi tradicionalni model upravljanja troškovima.

Što se tiče upravljanja, menadžeri u agrobiznisu, više razine menadžmenta, donose „neprogramirane“ odluke i djelomično su skloni riziku,... Srednji menadžment najčešće odlučuje neprogramirano i sklon je riziku,... Na nižim razinama menadžeri donose „programirane“ odluke i najviše su skloni riziku (Repar i sur., 2012).

Hajenić i Ivanković (2014) istraživali su karakteristike menadžera uzgajivača pasmine konja, hrvatskog posavca. Istraživanje je pokazalo da uzgajivače karakterizira dobra razina tradicijskih znanja i vještina, dobra socijalna povezanost, no naglašen je nedostatak „suvremenih“ znanja, investicijskog kapitala, kvalitetne radne snage, učinkovit pristup tržištu te vizija tržišnog razvoja gospodarstva. Unutarnja i vanjska analiza gospodarstava ukazala je na problematično poslovanje, ali i na ustrajnost u proizvodnji.

U upravljanju rizicima, ključnu ulogu imaju informacije i dostupnost podataka (Seccia i sur. 2016). Dercon (2000) u svom radu razmatra rizike zemalja u razvoju, Etiopije, i poteškoće s kojima se susreću poljoprivredna domaćinstva. U radu je naglašena važnost ekonomske politike, bolji rad tržišta nekretnina, makroekonomska stabilnost i dostupnost alternativnih ekonomskih aktivnosti te kao potencijalno korisna alternativa istaknute su „javne sigurnosne mreže“.

Knoeber i Thurman (1995), promatraju u SAD-u proizvođače brojlera i mjere cjenovni i proizvodni rizik. Proizvođači „prenose“ svoj cjenovni rizik putem proizvodnih ugovora.

Turvey i sur. (2012), simulacijom u proizvodnji mlijeka (New York, SAD), predlažu mehanizme za transfer rizika prihoda i to pomoću kreditnih proizvoda (op.a. „interventni krediti“) za nepredviđene rizike.

U istom poljoprivrednom sektoru, ali Švicarske, Benni i Finger (2013) promatraju način na koji su reforme poljoprivredne politike, uključujući liberalizaciju tržišta i deregulaciju tržišta, utjecale na rizik ukupnog prihoda. Zaključili su da švicarski proizvođači mlijeka mogu profitirati od „prirodnog *hedginga*<sup>1</sup>“, no tržišna deregulacija i liberalizacija tržišta smanjile su „prirodni *hedging*“ na razini farmi. Povećanje promjenjivosti cijena znatno će povećati rizik prihoda i zajedno s napuštanjem izravnih plaćanja smanjiti komparativnu prednost proizvodnje mlijeka za donositelje odluka nesklonih riziku.

Analiza Enjolras i sur. (2014) izravno dovodi u pitanje efikasnost strukturnih politika usmjerenih na osiguranje i stabilizaciju prihoda talijanskih i francuskih poljoprivrednika. Talijanske su farme manje od onih francuskih i time izloženije promjenama u prihodu, što ima za rezultat korištenje većeg raspona alata za povećanje prihoda (EU plaćanja, osiguranje). S obzirom na veću veličinu farmi, francuski poljoprivrednici zamjenjuju EU plaćanja s proizvodnjom. Primjena ovih strategija povećava rizik. Naime, oscilacije prihoda mnogo su veće kod francuskih poljoprivrednika.

---

<sup>1</sup> *Hedging* - zaštita i upravljanje financijskim rizicima (Redhead, 1997 iz Tuškan 2009)

Različiti su faktori koji utječu na donošenje odluka ovisno o vrsti alata za upravljanje rizicima. Najveći broj istraživanja rizika u poljoprivredi usmjeren je na strategije osiguranja i *hedginga*.

Glavnu funkciju upravljanja rizicima čini ocjena svih mogućnosti za upravljanje pojedinim rizicima uključujući samo-osiguranja i nakon toga odabir optimalnih alternativa (Brigham i Ehrhardt, 2011). Veća je vjerojatnost „kupovine“ osiguranja usjeva kod većih, „starijih“, visoko zaduženih farmi te onih s višom percepcijom rizika prinosa (Sherrick i sur., 2004). Što je područje razvijenije to je više izraženo odlučivanje tržišno orijentiranih poljoprivrednika. Slično je s usvajanjem novih tehnologija. Ako vlada osigura poticaje, zajmove s niskim kamatama, spremnost poljoprivrednika u usvajanju novih tehnologija povećava se za 40%. Stoga se kao rješenje vidi uvođenje tržišta prijenosa rizika (Aimin, 2010).

Za veliki broj poljoprivrednika u Georgiji (SAD), u području uzgoja kukuruza, soje i pamuka, navike i izvori informacija imaju veliku ulogu u odluci o *hedgingu*. Ostali važni faktori u odlučivanju o poljoprivrednom *hedgingu* uključuju stav prema usvajanju tehnologije (više *hedgiraju* oni koji ranije usvajaju tehnologiju), educiranost (veća educiranost znači i manji udio *hedginga*), profitabilnost gospodarstva (veća dobit znači manji *hedging*), i omjer vlastitih površina u odnosu na obrađivane površine (usmjerenost na unajmljene površine vodi prema manjem *hedge* udjelu) (Dorfman i Karali, 2008).

U svom istraživanju Székely i Pálinkás (2009) usporedili su upravljanje rizika poljoprivrednika SAD-a i odabranih zemalja EU-a, Njemačke, Mađarske, Poljske, Španjolske i Nizozemske. Naime, rizik fluktuacije cijena je, i za poljoprivrednike u SAD-u i u EU-u, najvažniji faktor rizika, dok je *hedging* popularniji kod poljoprivrednika u SAD-u. Kod obje promatrane skupine korištenje vladinih programa i sudjelovanje u diversifikaciji rizika predstavlja važne strategije za upravljanje rizikom. Zanimljivo je da obje skupine izbjegavaju zaduživanje u funkcioniranju pojedinih procesa poslovanja te nastoje koristiti druga rješenja, poput rezervi gotovine kako bi odgovorili na financijske izazove poslovanja.

Leat i Giha (2013) u svom radu promatraju jedan od glavnih opskrbnih lanaca svinjetine u Škotskoj. S obzirom na upravljanje tim rizicima izdvojeno je nekoliko zaključaka, dizajn lanca vrijednosti trebao bi uključivati fleksibilnost, razvijanje fokusa upravljanja rizicima, suradnju koja uvelike olakšava upravljanje rizicima, organizaciju „treće strane“ koja može omogućiti upravljanje rizicima, povoljniji poslovni ambijent, politiku i rezultate istraživanja. Rezultati istraživanja, Han i sur. (2007), kineskih klaonica i prerađivača svinjetine pokazuju pozitivnu povezanost upravljanja kvalitetom s učinkom poduzeća. Poduzećima se savjetuje,

s ciljem poboljšanja kvalitete proizvoda i smanjenja nesigurnosti u opskrbnom lancu, razvijanje snažnije integriranih veza s dobavljačima.

Uddin i sur. (2010) u svojoj studiji među ostalim zaključuju da struktura i naponi zadruga u opskrbnom lancu govedarske proizvodnje Australije trebaju težiti prema boljem protoku informacija i znanja i to za tržišno orijentirane opskrbe lance, a s ciljem boljeg upravljanja rizikom i nesigurnostima, i veće profitabilnosti.

U području vinarske proizvodnje Matarazzo i sur. (2008) razmatraju ulogu burze u razvoju inovativnih alata temeljem financijskih instrumenata za upravljanje rizicima. Čini se da strateško udruživanje ima svojstven učinak na reputaciju. Stoga se vinarije mogu profilirati i izgrađivati svoju reputaciju putem strateškog pozicioniranja.

Viviani (2006) predstavlja jedinstveni mehanizam za upravljanje rizikom prihoda u poljoprivredi te zaštite prihoda od fluktuacije cijene i proizvodnje, putem Inter-Rhône rezerve za proizvođače vina, stvaranjem zaliha. Analiza je uključivala simulaciju za dvije vrste rezervi (zaliha vina i financijske imovine).

U Hrvatskoj se istraživanjem rizika bavi mali broj znanstvenika.

Rizike i upravljanje rizicima kod velikih hrvatskih nefinancijskih poduzeća istražuju Sprčić i sur. (2008). Rezultati su pokazali da poduzeća primjenjuju prvenstveno jednostavne instrumente upravljanja rizicima („prirodni *hedging*“).

Sprčić i Šević (2008) istraživali su razlike u upravljanju rizicima i izvorima rizika velikih hrvatskih i slovenskih nefinancijskih poduzeća. Rezultati su među ostalim pokazali da na hrvatska poduzeća više utječe rizik tečaja. Hrvatska i slovenska nefinancijska poduzeća upravljaju financijskim rizicima prvenstveno jednostavnim instrumentima kao što je „prirodni *hedging*“.

Pitanjem postoji li, i kakva je, praksa upravljanja financijskim rizicima u hrvatskim poduzećima, te kojim su rizicima i u kojoj mjeri izložena poduzeća, bavili su se Sučić i sur. (2011). Rezultati istraživanja pokazali su da je rizik kojemu su hrvatska poduzeća najviše izložena, rizik promjene cijena *inputa* i *outputa*, slijedi valutni, rizik likvidnosti i kamatni rizik. Prilikom upravljanja rizicima najkorišteniji su jednostavni instrumenti, kao što je „prirodni *hedging*“. Sprčić (2007) analizira prakse korporativnog upravljanja rizicima i odluke o *hedgeu* velikih hrvatskih nefinancijskih poduzeća. Multivarijantna analiza pokazala je da „*hedgeri*“ imaju statistički veću vrijednost omjera (omjer troškova investiranja i imovine), sugerira pozitivnu vezu između vrijednosti investicije poduzeća i odluke o „*hedgiranju*“.



Matić i sur. (2010), uzimajući u obzir tržišni rizik, zaključuju da većina promatranih poduzeća analizira rizike primjenom tzv. "*rules of thumb*" ili uopće ne analizira tržišni rizik, jer bi troškovi premašili dobrobiti.

Malobrojni su autori koji istražuju rizike u poljoprivredi. Budin (1981) razmatra donošenje ekonomski racionalnih odluka u uvjetima neizvjesnosti i rizika od vremenskih prilika.

Izvore rizika i strategije upravljanja rizicima, vinogradarsko-vinarskih gospodarstava istražuju Gugić i sur. (2008) u Dalmaciji i Njavro i sur. (2005) na području Slavonije i Baranje.

Razlog istraživanja Tota i sur. (2008) visoka je rizičnost proizvodnje šećerne repe. U svom radu istražuju percepciju rizika kod proizvođača te zaključuju da su najčešći izvori rizika klimatske prilike, promjena cijena poljoprivrednih *inputa*, promjena cijena biljnih proizvoda i pojava bolesti i štetnika. Kao najvažnije strategije ističu proizvodnju za poznatog kupca (kooperacija), pridržavanje tehnologije i agrotehničkih rokova te prostorni i vremenski razmještaj proizvodnje.

Smrkulj i Njavro (2016) istražuju percepciju rizika i primjenu strategija vinogradarsko-vinarskih gospodarstava na području Zagorja i Međimurja. Vinogradari su relativno neskloni riziku, iako se u procesu poslovnog odlučivanja najviše oslanjaju na vlastito iskustvo, savjete udruga vinogradara te preporuke i kritike kupaca.

Prema pregledu istraživanja, proizvođači, poslovni subjekti, skloni su neovisno o vrsti poljoprivredne djelatnosti primjeni kombinacije nekoliko vrsta strategija. Na dobre odnose u poslovanju, a time i na ublažavanje rizika, uvelike utječe i povjerenje između proizvođača te proizvođača i kupaca.

U primjeni strategija upravljanja rizicima, proizvođači su skloniji primjeni „tehnoloških“ alata i strategija kao što su pridržavanje tehnologije proizvodnje, prodaja putem različitih kanala i proizvodnja za poznatog kupca, od korištenja proizvoda financijskog tržišta (*hedging*, osiguranje).

## 4. MATERIJAL I METODE RADA

### 4.1. Materijal

Materijal istraživanja čine primarni i sekundarni izvori podataka.

Primarni izvori podataka istraživanja su:

Anketa za izradu SWOT analize stanja vinarskog sektora u Republici Hrvatskoj. Ciljna skupina anketnog ispitivanja bili su eksperti vinogradarstva i vinarstva. Anketa je dostavljena prema 38 eksperata putem e-maila. Istraživanju se odazvalo 25 ispitanika.

Anketa za analizu percepcije menadžera o rizicima u vinarijama Republike Hrvatske „Strateško upravljanje rizikom vinarija u Hrvatskoj“. Ciljna skupina ovog dijela istraživanja bile su vinarije odnosno poslovni subjekti, fizičke i pravne osobe u Republici Hrvatskoj koji proizvode vino od grožđa te prema Nacionalnoj klasifikaciji djelatnosti 2007. (NKD 2007. Vlada Republike Hrvatske, 2007) imaju registriranu proizvodnju vina od grožđa. Za odabir uzorka korišteni su podaci Hrvatske gospodarske komore i Zavoda za vinogradarstvo i vinarstvo Hrvatskog centra za poljoprivredu, hranu i selo. Podaci Hrvatske gospodarske komore uključivali su 200 najvećih vinarija i 100 najvećih proizvođača grožđa prema prihodu. Proizvođači grožđa su uključeni kako bi se obuhvatilo što više proizvođača i zbog pretpostavke da značajan broj proizvođača proizvodi osim grožđa i vino. Podaci Zavoda za vinogradarstvo i vinarstvo Hrvatskog centra za poljoprivredu, hranu i selo uključivali su 300 najvećih vinarija prema količinama za koje je izdano rješenje za promet vina u 2014. godini.

Objedinjavanjem primljenih podataka, od ukupno 600 poslovnih subjekata te izuzimanjem ponavljanja subjekata, od ukupno 519 subjekata poveznica za anketu odaslana je na 347 email adrese poslovnih subjekata. Prema 172 subjekta nisu odaslane email poruke s poveznicom za anketu. Neki od razloga bili su nemogućnost telefonskog kontaktiranja s ispitanicima o email podacima, ispitanici nisu imali email, nije naznačen kontakt telefon, ispitanici su izrazili želju da ne sudjeluju u anketiranju ili imaju zatvorenu djelatnost. Prema strukturi subjekata, a koji unutar naziva imaju naznačenu vrstu djelatnosti, 151 subjekt registriran je kao društvo ograničene odgovornosti (d.o.o.), 143 subjekta registrirana su kao obrt, obiteljsko poljoprivredno gospodarstvo, ili nisu imali naznačenu vrstu djelatnosti unutar naziva subjekta, 28 subjekata registrirani su kao zadruga, 18 subjekata registrirani su kao dioničko društvo (d.d.), 4 kao jednostavno društvo ograničene odgovornosti (j.d.o.o.) i 3 su bile institucije. Prema zemljopisnoj rasprostranjenosti poslovnih subjekata, najveći broj subjekata bio je iz Istarske, Dubrovačko-neretvanske i Međimurske županije (tablica 1).

Tablica 1: Prikaz broja odaslanih anketa prema županijama

Županija	Broj subjekata
Istarska županija	67
Dubrovačko-neretvanska županija	54
Međimurska županija	28
Splitsko-dalmatinska županija	28
Zagrebačka županija	24
Požeško-slavonska županija	23
Vukovarsko-srijemska županija	17
Osječko-baranjska županija	16
Grad Zagreb	15
Zadarska-županija	13
Primorsko-goranska županija	10
Varaždinska županija	9
Krapinsko-zagorska županija	8
Šibensko-kninska županija	8
Sisačko-moslavačka županija	7
Virovitičko-podravska županija	5
Bjelovarsko-bilogorska županija	4
Brodsko-posavska županija	4
Koprivničko-križevačka županija	4
Karlovačka županija	2
Ličko-senjska županija	1
<b>Ukupno</b>	<b>347</b>

Sekundarni izvori podataka jesu:

U izradi pregleda stanja sektora, vinogradarskih površina, proizvodnje grožđa i vina, potrošnje vina, za razdoblje od 2005. do 2015. korišteni su podaci Državnog zavoda za statistiku Republike Hrvatske. U dijelu pregleda stanja prometa vina, uvoza i izvoza vina promatrano je razdoblje od 2011. do 2015. i korišteni su podaci Hrvatskog centra za poljoprivredu, hranu i selo, Državnog zavoda za statistiku Republike Hrvatske i Agencije za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju.

U pregledu vinarskog sektora Europe i svijeta, vinogradarskih površina, proizvodnje grožđa i vina, potrošnje vina, uvoza i izvoza vina promatrano je razdoblje od 2000. do 2015. i za materijal su korišteni podaci OIV-a. Analiza prema pojedinim državama članicama Europske unije obuhvatila je razdoblje od 2005. do 2015. i podatke Eurostata.

Materijal u kvantifikaciji rizika, korelaciji čimbenika rizika, za primjenu regresijske analize, u dijelu istraživanja vezanog za uklapanje procesa upravljanja rizikom u scenarije strateškog menadžmenta predstavljali su sekundarni izvori podataka, podaci FINA-e o poslovnim

subjektima za razdoblje od 2011. do 2015. godine i Državnog zavoda za statistiku Republike Hrvatske za razdoblje od 2005. do 2015.

Korišteni su podaci o poslovnim subjektima iz FINA-e, koji su naznačili prema NKD-u za područje djelatnosti prerađivačku industriju i za razred djelatnosti naveli proizvodnju vina od grožđa (1102) te su imali dostupne financijske izvještaje (bilancu stanja i račun dobiti i gubitka) za cijelo razdoblje promatranja. U analizi su korišteni i ostali opći podaci o poslovnim subjektima dostupni u FINA-i.

Za analizu institucionalnog rizika promatrana je promjena poljoprivredne politike, standarda kvalitete, uvozno-izvozne politike temeljem desk istraživanja.

## 4.2. Metode rada

U metodama rada korištene su metode analize rizika, regresijska i korelacijska analiza, stohastičke simulacije, metode strateškog upravljanja, anketno ispitivanje i financijska analiza.

### 4.2.1. Metode analize rizika

Razdioba (distribucija) vjerojatnosti nastupanja mogućih rezultata, kao posljedica neke odluke o investiranju, osnova je procjene rizika. Razdioba vjerojatnosti može se definirati kao određen skup mogućih rezultata s poznatim vjerojatnostima nastupanja svakog pojedinog rezultata. Ona prikazuje na koji je način ukupna vjerojatnost raspodijeljena na pojedine vrijednosti mogućeg rezultata. Pri tome su vjerojatnosti nastupanja pojedinog rezultata normalizirane (njihov zbroj iznosi jedan), dok se rezultati (prinosi) razmatraju ovisno o podrazumijevanom stanju gospodarstva (tipične gospodarske situacije jesu recesija, normalno stanje i prosperitet, odnosno ekspanzija, uzlet). Svakom od scenarija treba pridati određenu vjerojatnost. Spajanjem očekivanog rezultata s vjerojatnošću njegovog ostvarenja dobiva se razdioba vjerojatnosti. Normalna razdioba često se koristi u opisivanju mogućih ishoda i vjerojatnosti nastupa istih. Ona govori o prirodi nasumičnosti, čiji smisao je u tome da kada se stvari mijenjaju, nastoje ostati u blizini točke prosjeka, te se raspoređuju oko tog prosjeka po glatkoj, zvonolikoj krivulji. Slučaj u sredini je najvjerojatniji i poduzeće se ponaša u skladu s tim ako ne dođe do promjene u razdiobi (Deković i sur., 2017). Normalnu razdiobu opisuju dva parametra - distribucija vjerojatnosti i standardna devijacija. Razdioba vjerojatnosti - očekivani prinos (povrat) ili  $E(r)$  (eng. *expected return*) je ponderirani prosjek mogućih prinosa, gdje su ponderi vjerojatnosti ostvarivanja. Disperzija oko ove srednje vrijednosti može se uzeti kao mjera rizika, a kao mjera disperzije koristi se varijanca, odnosno standardna devijacija. Veličina disperzije

razdiobe vjerojatnosti koristi se kao mjera rizika putem izračunavanja standardne devijacije. Niska standardna devijacija ukazuje na višu pouzdanost realizacije događaja i označava užu distribuciju vjerojatnosti. Zato se za vrijednosnicu čiji prinosi vjerojatno neće odstupati mnogo (ako će uopće odstupati) od svog prosječnog ili očekivanog prinosa kaže da nosi mali ili nikakav rizik, dok se za vrijednosnicu čiji su prinosi iz godine u godinu nepostojani (i za koje su veliki gubici tipični u pojedinim godinama) kaže da je rizična. Varijanca povrata ( $\sigma^2$ ) je mjera disperzije prinosa. Definira se kao prosječno kvadratno odstupanje svakog posebnog prinosa od prosječne (očekivane) vrijednosti prinosa. Standardna devijacija povrata ( $\sigma$ ) tj. drugi korijen iz varijance je srednje kvadratno odstupanje pojedinačnih vrijednosti jedinica statističkog skupa od aritmetičke sredine. Standardna devijacija pokazuje prosječno odstupanje od očekivanog prinosa. Što je odstupanje veće, veća je neizvjesnost u pogledu mogućeg prinosa i obratno (Deković i sur., 2017).

Korištene su metode koje omogućavaju spoj rizika očekivanja u jedan broj, kretanje dohotka pri riziku (EaR) i novčanog toka pri riziku (*Cash flow-at-risk* ili CFaR). Novčani tok pri riziku koristi se kao metoda koja omogućava spoj rizika, odnosno očekivanja negativnih poslovnih rezultata u jedan broj. To je prikladan instrument pri integriranom upravljanju poslovnim rizicima. CFaR uključuje simulacije poslovnih pokazatelja poduzeća koje omogućavaju procjenu vjerojatnosti nastupanja financijskih poteškoća ili stečaja poduzeća u dužem vremenskom razdoblju (Miloš Sprčić i Radić, 2011). EaR vrijednost u izradi doktorskog rada definirana je vjerojatnošću zarade pri riziku odnosno razdiobom u negativnom djelu. Pri tome je važno da „negativnost događaja“ bude što manja.

Za analizu rizika definirana je funkcija razdiobe za najvažnije izvore rizika u desetogodišnjem razdoblju, od 2005. do 2015. godine odnosno za poslovne subjekte u petogodišnjem razdoblju, od 2011. do 2015. U analizi distribucije razdiobe proizvodnog rizika promatrana je promjena proizvodnje i promjena prinosa. Za tržišni rizik analizirane su promjene cijena *inputa* grožđa za vino, električne energije, pare i vrele vode, benzina iz fosilnih sirovina, dizelskih goriva iz fosilnih sirovina, ekstralakog i specijalnog loživog ulja, niskosumpornog loživog ulja, visokosumpornog loživog ulja, prirodnog plina distribuiranog mrežom, ukapljenog plina. Kod financijskog rizika analizirana je distribucija zaduženosti, ROA, ROE te Altmanovog A-Z-score za vinarije u Hrvatskoj, koje su imale dostupne podatke za cijelo razdoblje od 2011. do 2015. godine.

– Bodovna ljestvica rizika (*Risk Scorecards*)

Bodovna ljestvica rizika (*risk scorecard*) prikazana je na osnovi rada Jaffee i sur. (2010). U rangiranju očekivanih gubitaka (matrice gubitaka) prioritet 1 pretpostavlja vrlo vjerojatnu ili vjerojatnu vjerojatnost događaja i značajnu, kritičnu ili katastrofalnu posljedicu utjecaja. Prioritet 2 pretpostavlja povremenu ili malu vjerojatnost i značajnu, kritičnu ili katastrofalnu posljedicu. Prioritet 2 uključuje i vrlo vjerojatnu, vjerojatnu i „nevjerojatnu“ vjerojatnost događaja i umjerenu ili katastrofalnu posljedicu utjecaja. Prioritet 3 pretpostavlja sve vjerojatnosti događaja i zanemarivu posljedicu utjecaja, nakon toga povremenu, malu ili „nevjerojatnu“ vjerojatnost i umjerenu posljedicu. Prioritet 3 uključuje i mogućnost „nevjerojatne“ vjerojatnosti događaja i značajne ili kritične posljedice utjecaja (slika 2).

		Potencijalna posljedica utjecaja				
		Zanemariva	Umjerena	Značajna	Kritična	Katastrofalna
Vjerojatnost događaja	Vrlo vjerojatna					
	Vjerojatna					
	Povremena					
	Mala					
	Nije vjerojatna					

Prioritet 1 = Očekuju se visoki gubici, Prioritet 2 = Očekuju se srednji gubici,  
Prioritet 3 = Očekuju se niski gubici

Slika 2: Rangiranje očekivanih gubitaka (vjerojatnost x snaga)


Izvor: Jaffee i sur. (2010)

U radu je primijenjen izračun rezultata rizika, umnožak srednje vrijednosti vjerojatnosti pojave rizika i srednje vrijednosti posljedice pojave rizika za grupe rizika.

– Stablo odlučivanja

Stablo odlučivanja mapa je mogućih rješenja u različitim fazama procesa odlučivanja. Ta je tehnika pogodna kada se od menadžera traži donošenje niza sekvencijalnih odluka, odnosno – kada se odluke donose „u nizu“ u kojemu svaka odluka bitno utječe na sljedeću fazu procesa odlučivanja (Tomašević, 2007).

Izrada stabla odlučivanja koristi se znakovima (kružićima, kvadratićima i trokutićima) i linijama koje povezuju te znakove. Svi znakovi imaju svoje nazive i svoje značenje, i to su čvor odluke (od kojeg polazi graf) ili mogući izbori, čvor stanja (od njega polaze moguća stanja), čvor posljedica koji predstavlja obvezatni završetak svakog od utvrđenih putova i grana (predstavlja jednu od alternativa u procesu izbora). Svaka grana započinje i završava određenim čvorom, a ona posljednja završava čvorom posljedica (Buble, 2000) (slika 3).



Slika 3: Stablo odlučivanja

Izvor: prema Decission Tree Primer (2007)

Stablo odlučivanja kreirano je primjenom softverskog dodatka @Risk.

U stablu odlučivanja promatrano je „poslovanje kao i obično“ bez primjene ERM-a (*eng. Enterprise Risk Model*, modela upravljanja rizikom poduzeća) i poslovanje primjenom ERM modela. U poslovanju primjenom ERM-a, razrađen je scenarij troškovne fleksibilnosti, širenja na tržištu i stabilnije prodaje.

#### 4.2.2. Regresijska i korelacijska analiza

##### – Regresijska analiza

Regresijski je model algebarski model i u pravilu je to jednačica koja sadrži varijable i parametre. Model jednostavne linearne regresije prikladan je za opisivanje odnosa između pojava, a za nj je svojstveno da promjenu jedne pojave prati linearna promjena druge. U analizi višestrukih odnosa promjena jedne pojave prati se pod utjecajem dviju ili više drugih (nezavisnih) pojava. Polazni je opći aditivni model ili multiplikativni. Za primjenu modela nužno je odrediti koja je varijabla zavisna, a koja (koje) su nezavisne. Zatim valja utvrditi oblik funkcije u modelu (deterministički dio modela) te svojstva slučajne varijable (Šošić i Serdar, 1997).

Model jednostavne linearne regresije s procijenjenim parametrima za n opažanja dan je izrazom:

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1}, \quad i = 1, 2, \dots, n$$

Model višestruke linearne regresije s procijenjenim parametrima za k- nezavisnih varijabli i n opažanja dan je izrazom:

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_j x_{ij} + \dots + \hat{\beta}_k x_{ik}, \quad i = 1, 2, \dots, n$$

(Čižmešija, 2016 a, b)

Postupak provođenja regresijske analize obuhvaća, nakon procjene parameta izračun pokazatelja reprezentativnosti procijenjenih modela (koeficijent determinacije, procjena varijance i standardne devijacije regresije), provođenje statističkih testova značajnosti nezavisnih varijabli u modelu (uz standardnu razinu značajnosti testa  $\alpha = 0,05$ ), izračun granica intervala procjene parametra (uz pouzdanost procjene  $(1-\alpha) = 0,95$ ). U regresijskoj analizi ispituje se potencijalno postojanje problema multikolinearnosti, heteroskedastičnosti grešaka relacije (Whiteov test heteroskedastičnosti), autokorelacije grešaka relacije prvoga i višega reda (Durbin-Watsonov test, Ljung-Boxov Q-test) i problem nenormalnosti rasporeda grešaka relacije (Jarkue-Bera tst). Kako bi se analizirao relativni utjecaj nezavisnih varijabli na zavisnu varijablu, procjenjuju se parametri u regresijskim modelima sa standardiziranim varijablama. Kada su vrijednosti varijabli standardizirane, što znači da je prosječna vrijednost jednako nula i varijanca odnosno standardna devijacija jednako 1, procijenjeni parametri interpretiraju se u mjernim jedinicama standardnih devijacija varijabli.



Nezavisna varijabla koja ima izraženiji relativni utjecaj na zavisnu varijablu generira veći rizik (Čižmešija, 2016, a, b, Čižmešija 2017).

Model jednostavne linearne regresije s procijenjenim parametrima za standardizirane varijable za  $n$  opažanja dan je izrazom:

$$\hat{y}_i^* = \hat{\beta}_1^* x_{i1}^*, \quad i = 1, 2, \dots, n$$

Model višestruke linearne regresije s procijenjenim parametrima za  $k$ - nezavisnih varijabli i  $n$  opažanja, sa standardiziranim vrijednostima, dan je izrazom:

$$\hat{y}_i^* = \hat{\beta}_1^* x_{i1}^* + \hat{\beta}_2^* x_{i2}^* + \dots + \hat{\beta}_j^* x_{ij}^* + \dots + \hat{\beta}_k^* x_{ik}^*, \quad i = 1, 2, \dots, n$$

(Čižmešija, 2016, a, b)

Multikolinearnost je problem uzorka, a ne populacije. Multikolinernost je često prisutna u regresijskim modelima. Visoka koreliranost regresorskih varijabli ne mora uvijek biti problem u empirijskim istraživanjima. Naime, ako je varijanca grešaka relacije mala, a varijance regresorskih varijabli dovoljno velike, velika koreliranost regresorskih varijabli neće rezultirati nerealno visokim procjenama standardnih pogrešaka procijenjenih parametara, a time i netočnim zaključcima. Problem heteroskedastičnosti također je čest u empirijskim istraživanjima. U analizi financijskih podataka varijanca (standardna devijacija) povezuje se s rizikom koji se mijenja tijekom analiziranog razdoblja. Ako se analiziraju pokazatelji uspješnosti poduzeća različitih veličina, a zanemaruje se veličina poduzeća, varijanca također neće biti konstantna (Bahovec i Erjavec, 2015).

Prije regresijske analize, uobičajeno se provodi korelacijska analiza. Temeljem rezultata korelacijske analize odabiru se (korelirane, važne) varijable za daljnju regresijsku analizu. Cilj regresijske analize na uzorku veličine 95 poslovnih subjekata ( $n = 95$ ) bio je utvrditi utjecaj nezavisnih varijabli na zavisnu varijablu (ukupan prihod u milijunima kuna). Od nezavisnih varijabli korištene su sljedeće numeričke varijable: broj zaposlenih, materijalni troškovi, trošak osoblja i zalihe. Financijski pokazatelji nisu promatrani jer su oni velikim dijelom izračunani iz podataka o ukupnim prihodima, a upravo je ukupni prihod zavisna varijabla.

U modele su uvrštene i *dummy* (binarne) varijable: pravni status, veličina i domaći kapital i županija.

Kvalitativne varijable s dva modaliteta definirane su na sljedeći način:

- Pravni status: 0 – d.d., zadruge i ostalo; 1 – d.o.o.,
- Veličina: 0 – srednje velike vinarije; 1 – male vinarije,
- Domaći kapital: 0 – udio domaćeg kapitala manji od 100%; 1 – isključivo domaći kapital (100%),
- Županija: 0 – Primorska Hrvatska; 1 – Kontinentalna Hrvatska

Ostale varijable u regresijskim modelima numeričke su varijable izražene u navedenim mjernim jedinicama, a pojedinačne vrijednosti dane su kao srednje vrijednosti godišnjih podataka za razdoblje od 2011. do 2015. godine.

U provođenju regresijske analize korištene su sljedeće kratice:

- UP – ukupan prihod
- UR – ukupan rashod
- PR – poslovni rashod
- BZ – broj zaposlenih
- MT – materijalni troškovi
- TO – trošak osoblja
- PS – pravni status
- V – veličina
- DK – domaći kapital
- Ž – županija

Ponajprije je pristupljeno procjeni parametara u modelu višestruke regresije, no rezultati su se pokazali nezadovoljavajućima za interpretaciju zbog nemogućnosti udovoljavanja pretpostavkama primjene modela višestruke regresije, uočene tijekom provođenja postupaka regresijske dijagnostike. Potom je pristupljeno jednostavnoj regresiji uz usporedbu ukupnih prihoda (kao zavisne varijable) i posebno svake od nezavisnih varijabli, bez *dummy* varijabli. Regresijska analiza pripremljena je pomoću softvera EViews 7.0.

#### – Korelacijska analiza

Koeficijenti korelacije pokazatelji su stupnja statističkih veza. Stupanj statističke ovisnosti jedne pojave od dviju ili više drugih pojava izražava se pomoću koeficijenta multiple (linearne) korelacije (Šošić i Serdar, 1997). Analiza korelacije koristi se za opis jačine i smjera linearne povezanosti između dvije varijable. U analizi korelacije primijenit će se Pearsonov koeficijent korelacije ( $r$ ). Koeficijent može imati vrijednosti od -1 do +1. Korelacija 0 označava da nema povezanosti, dok korelacija od 1,0 označuje savršenu pozitivnu korelaciju i vrijednost -1,0 označava savršenu negativnu korelaciju (Pallant, 2005). U daljnjoj analizi napravljena je korelacija, Pearsonov koeficijent korelacije ( $r$ ). Rezultati su uspoređivani s vrijednostima Pearsonovog koeficijenta korelacije ( $r$ ) (Cohen, 1988, iz Pallant, 2005):  $r = 0,10$  do  $0,29$  ili  $r = -0,10$  do  $-0,29$  mala,  $r = 0,30$  do  $0,49$  ili  $r = -0,30$  do  $-0,49$  srednja,  $r = 0,50$  do  $1,0$  ili  $r = -0,50$  do  $-1,0$  velika. U radu je primijenjen opis „značajno“ umjesto „veliko“.

Korelacijska analiza primijenjena je u analizi podataka anketnih ispitivanja SWOT analize stanja vinarskog sektora u Republici Hrvatskoj i anketi „Strateško upravljanje rizikom vinarija u Hrvatskoj“ i izloženosti vinarija riziku (korelacija prosječnih proizvođačkih cijena i jedinične cijene s cijenom utroška *inputa* po jedinici mjere).

#### 4.2.3. Stohastičke simulacije

Simulacije su prikladan alat za analizu rizika, usporedbu dvije ili više odluka, analizu rizičnih investicija. Svrha simulacija u analizi rizika jest procijeniti distribuciju ekonomskih povrata sredstava za alternativne strategije, kako bi donosioci odluka mogli lakše upravljati svojim odlukama. Simulacija nikada ne bi trebala biti točka procjene (Richardson i sur., 1997). Law i Kelton, 1982. godine naveli su korake simulacijskog procesa, a to su: definiranje cilja simulacijske studije, identifikacija sustava, prikupljanje podataka o sustavu i njihova analiza, izgradnja simulacijskog modela i programa, verifikacija simulacijskog programa i njegovo vrednovanje, planiranje simulacijskih eksperimenata i njihovo izvođenje, analiza rezultata eksperimenata i u konačnici zaključci i preporuke (Božikov, 2007).

Simulacijski model odgovara na pitanje „koja je vjerojatnost ishoda?“. Svi simulacijski modeli mogu biti deterministički ili stohastički. Deterministički model simulacijski je model bez rizika, a stohastički model deterministički je model s uključenim rizikom. Stohastičkom varijablom smatra se svaka varijabla koju odgovorne osobe odnosno donosioci odluka ne mogu kontrolirati. Stohastičke varijable imaju dvije komponente, determinističku i stohastičku. Deterministička je komponenta ona koju poznajemo sa sigurnošću. Za normalnu ili empirijsku distribuciju ona je sredstvo predviđanja. Deterministička

komponenta pozicionira distribuciju po cijeloj numeričkoj skali. Stohastička komponenta određuje raspon vrijednosti o determinističkoj komponenti, standardnu devijaciju normalne distribucije (Richardson i sur., 1997).

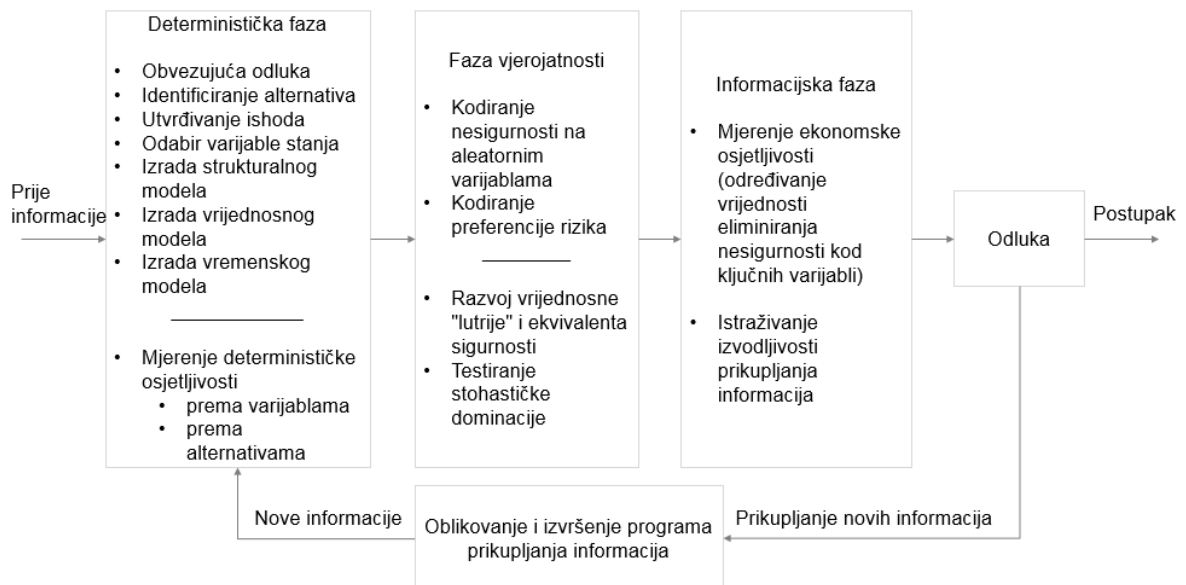
Za potrebe određivanja primjene strateškog upravljanja rizikom u vinarijama kreiran je model (slika 4, slika 5). U radu *input* varijable predstavljaju izvori rizika kroz funkciju razdiobe. Zbog holističkog pristupa bilo je važno sagledati međusobnu povezanost rizika i poslovnog rezultata za što je poslužila korelacijska matrica. *Output* varijable predstavljaju elementi bilance (imovina, obveze, kapital), račun dobiti i gubitka (prihodi, troškovi poslovanja, dobit prije kamata - EBITDA, dobit prije kamata i poreza - EBIT, bruto i neto dobit) i pokazatelji uspješnosti poslovanja (neto dug, povrat na imovinu - ROA, povrat na kapital - ROE, razina zaduženosti i Altmanov A-Z-score model).

Stohastičke simulacije pripremljene su primjenom softverskog dodatka @Risk.

Rast vinarije može se izračunati i prema sljedećoj formuli:

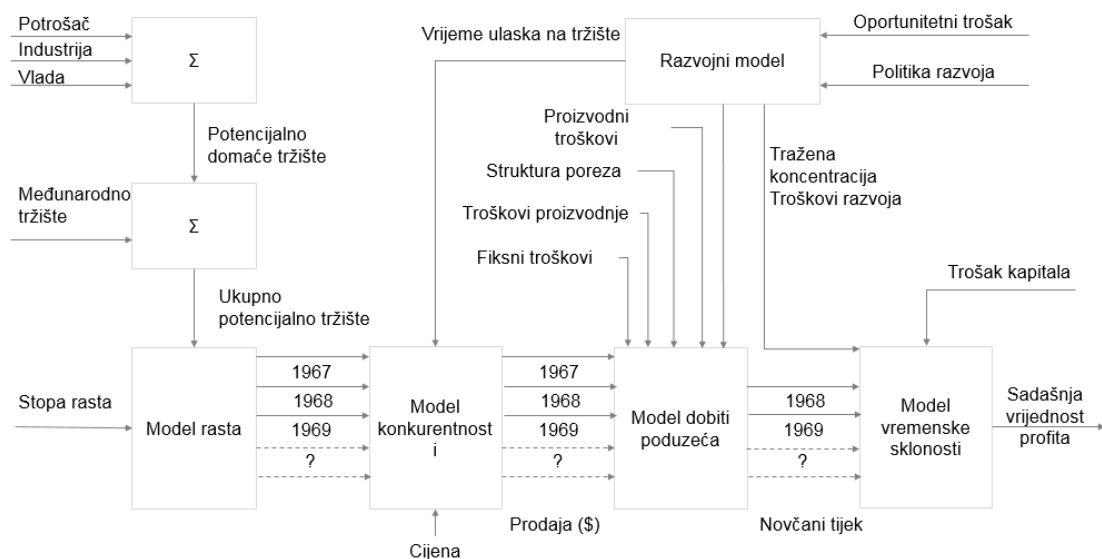
$$g = (ROA \times A/E - i \times D/E)(1-t)(1-c),$$

$g$  = stopa rasta,  $i$  = prosječna kamatna stopa na kredit (5%),  $t$  = stopa poreza na dobit (20%),  $c$  = dividende, stopa povlačenja sredstava (Barry i sur., 2000).



Slika 4: Ciklus analize odlučivanja

Izvor: Kaufman i Thomas (1977)



Slika 5: Strukturalni model za uvođenje novog proizvoda

Izvor: Kaufman i Thomas (1977)

#### 4.2.4. Metode strateškog upravljanja

U radu su korištene metode strateškog upravljanja, SWOT, PEST i analiza konkurencije pomoću Porterovog modela pet sila. Analiza konkurencije Porterovog modela pet sila uključena je u anketu „Strateško upravljanje rizikom vinarija u Hrvatskoj“.

##### – PEST analiza

PEST analiza obuhvaćala je *desk* istraživanje političkih (vezano uz zakonsku legislativu), ekonomskih, društvenih i kulturoloških, tehnoloških i proizvodnih čimbenika vinarske proizvodnje u Hrvatskoj.

##### – SWOT analiza

SWOT analiza predstavlja tehniku za razumijevanje snaga i slabosti te prilika i prijetnji s kojima se poduzeće susreće (slika 6). U radu se primjenjuje SWOT analiza stanja vinskog sektora u Republici Hrvatskoj temeljem anketnog ispitivanja eksperata.


	Pomažu	Štete
Unutarnje	SNAGE S	SLABOSTI W
Vanjske	PRILIKE O	PRIJETNJE T

Slika 6: SWOT analiza

Izvor: Cornell University Library (2017)

– Model Porterovih pet sila

Prema Porteru, priroda konkurentnosti u pojedinoj industriji može se promatrati kao djelovanje pet sila, suparništvo između konkurentskih poduzeća, potencijalni ulazak novih konkurenata, potencijalni razvoj zamjenskih proizvoda, pregovaračka snaga dobavljača, pregovaračka snaga potrošača (slika 7, David, 2011).



Slika 7: Model Porterovih pet sila

Izvor: David (2011)

U radu je primijenjen model Porterovih pet sila unutar identifikacije rizika i strategija vinarija u Hrvatskoj u anketi „Strateško upravljanje rizikom vinarija u Hrvatskoj“.

#### 4.2.5. Anketno ispitivanje

Tijekom istraživanja za potrebe izrade doktorskog rada kreirana su dva anketna upitnika i provedeno je anketiranje u slučajevima: 1. strateškog upravljanja, analiza stanja vinarskog sektora u Republici Hrvatskoj i 2. percepcije rizika, Strateško upravljanje rizikom vinarija u Hrvatskoj.

##### 1. Analiza stanja vinarskog sektora u Republici Hrvatskoj

Anketno ispitivanje eksperata predstavljalo je podlogu za SWOT analizu stanja vinarskog sektora u Republici Hrvatskoj. Anketa je provedena tijekom 2013. i 2014. godine. U pripremi ankete za ocjenu stanja sektora varijablama SWOT analize Maletića i sur. (2012) pridodana je Likertova skala, prema kojoj su ispitanici ocjenjivali ponuđene varijable ocjenama od 1 do 5. Anketa je sadržavala četiri grupe pitanja vezanih za ocjenu snaga, slabosti, prilika i prijetnji sektora, a koja su unutar grupe uključivala pitanja vezana za pitanja tehnologije, upravljanja i tržišta.

U grupi pitanja o snagama vinarskog sektora ispitanici su bili ocjenjivali snage sektora ocjenama od 1 do 5, pri čemu vrijednost 1 pretpostavlja najslabiju snagu dok ocjena 5 pretpostavlja najjaču snagu sektora. U grupi pitanja o slabostima sektora ispitanici su ocjenjivali slabosti sektora ocjenama od 1 do 5, pri čemu vrijednost 1 pretpostavlja najmanju slabost dok ocjena 5 pretpostavlja najveću slabost. Unutar grupe pitanja o prilikama sektora ispitanici su ocjenjivali prilike sektora ocjenama 1 do 5, pri čemu ocjena 1 pretpostavlja najvažniju prednost dok ocjena 5 pretpostavlja najmanje važnu prednost. U grupi pitanja o prijetnjama sektoru ispitanici su ocjenjivali prijetnje sektoru ocjenama 1-5, pri čemu ocjena 1 pretpostavlja najvažniju prijetnju, dok ocjena 5 pretpostavlja najmanju prijetnju. Radi lakše obrade podataka pitanja su grupirana prema pojedinim područjima vinarske proizvodnje (shema 1, shema 2).

Snage		Slabosti	
Turizam	Turizam	Državna administracija	Skupa i složena birokracija
Prirodni resursi	Okolišni uvjeti za vinogradarsku proizvodnju, vrhunskih položaji za uzgoj visoko kvalitetnog grožđa, autohtone sorte vinove loze, mogućnosti razvoja ekološkog vinogradarstva	Ljudski resursi	Problem radne snage, neorganiziranost vinogradara, slaba informiranost i poduzetničke vještine, manjak stručne pomoći i visoke cijene konzaltinga
Know how	Tradicija bavljenja uzgojem vinove loze, veći broj školovanih enologa - baza stručnjaka u proizvodnji	Tržište	Cjenovna nekonkurentnost, zalihe vina, nedostatak marketinga vina, niske cijene za prodaju vina u rinfuzi, sivo/crno tržište, šverc grožđa i vina, problemi u plasmanu vina u ugostiteljstvu
Tržište	Tržna pozicija i imidž vinorodnog područja na domaćem tržištu, povjerenje potrošača	Tehnologija	Stari vinogradi u lošoj kondiciji, male usitnjene površine, mali broj površina pod navodnjavanjem, otežana ili nemoguća primjena suvremene tehnologije, zastarjela tehnologiju, orijentiranost na prinos
		Izvori financiranja	Male potpore za otežane uvjete gospodarenja

Shema 1: Grupe snaga i nedostataka sektora vinarstva Republike Hrvatske

Prilike		Prijetnje	
Nove tehnologije	Nove tehnologije	Državna administracija	Ukidanje carina prema EU-u i smanjenje carina prema „novim“ vinskim zemljama, crno tržište i odsustvo inspekcijskog nadzora, nesređeno i komplicirano zakonodavstvo, nesređeno vlasništvo nad nekretninama
Turizam	Porast turističke potražnje, razvoj elitnog turizma, razvoj agroturizma i vinskog turizma	Tržište	Uvoz jeftinog grožđa i vina, pad cijena vina i grožđa, ponuda jednako kvalitetnih vina po nižim cijenama, gospodarska kriza i pad potražnje vina, gospodarska kriza i pad kupovne moći domaćeg stanovništva, preferencije tržišta/drugi tip vina, koncentracija vinske industrije, daljnje jačanje trgovačkih lanaca, kriza u zadrugarstvu, neplaćanje i nelikvidnost, gubitak identiteta kroz globalizacijske procese
EU - ruralni razvoj	Obveza planiranja ruralnog razvoja, EU programi za ruralni prostor, očuvanje tradicionalnih gospodarskih aktivnosti i očuvanje bioraznolikosti	Ljudski resursi	Manjak motivacije za vinogradarstvo
Tržište	Regulacija tržišta vina u EU-u, povećanje tržišta – ulazak u EU, veći protok ideja, ljudi i kapitala, porast potražnje za posebnim vinima (vrhunska kakvoća, autohtone sorte, ekološka proizvodnja), razvoj tržišta/dolazak novih vinskih poduzetnika, novi oblici prodaje - web prodaja	Tehnologija	Promjena strukture i teksture tla upotrebom teške mehanizacije, klimatske promjene, problem navodnjavanja, zaštita od bolesti i štetnika
Ekologija i održivi razvoj	Važnost ekološkog uzgoja, rast svijesti o nužnosti održivog razvoja i očuvanju tradicijskog, kulturnog i povijesnog nasljeđa	Masovni turizam, onečišćenje okoliša	Masovni turizam, onečišćenje okoliša

Shema 2: Grupe prilika i prijetnji sektora vinarstva Republike Hrvatske



## 2. Strateško upravljanje rizikom vinarija u Hrvatskoj

U ocjeni vjerojatnosti nastanka rizika, posljedice nastanka rizika, važnosti primjene i učestalosti primjene strategija provedeno je anketno ispitivanje „Strateško upravljanje rizikom vinarija u Hrvatskoj<sup>2</sup>“. Anketa je provedena tijekom 2015. godine. U pripremi ankete korišteni su različiti izvori iz literature (prilog 1).

Anketa je uključivala pitanja o strateškom upravljanju i strateškom upravljanju rizicima u poduzeću, izvorima rizika, vjerojatnosti nastanka i posljedicama te strategijama za upravljanje rizicima.

Ispitanici su u anketi ocjenjivali izvore rizika. Popis izvora podataka nalazi se u prilogu rada.

Prema radu Jaffee i sur. (2010), rizici su grupirani u pet osnovnih grupa:

- prirodne nepogode /katastrofe: klimatske promjene (prirodne nepogode,...),
- biologija i okoliš: onečišćenje okoliša (ekologija), pojava bolesti i štetnika,
- tržište: rizik loše reputacije vina, reputacijski rizik tvrtke, gubitak identiteta tvrtke kroz globalizacijske procese, dugo razdoblje naplate, poštivanje ugovornih obveza (kupci i dobavljači), nejasno i nedovoljno definirani uvjeti, promjenjivost cijene *inputa* (rast cijena *inputa*), promjenjivost cijene vina (pad cijena *outputa*), jačanje konkurencije/jačanje konkurentskih tvrtki, jačanje pregovaračke snage dobavljača, jačanje pregovaračke snage potrošača, trgovačkih lanaca, restorana, razvoj zamjenskih proizvoda (preferencije potrošača mijenjaju se u korist piva, ...), promjene preferencija tržišta (...drugi „tip“ vina), ovisnost o turističkoj potražnji, pad potražnje za vinom uzrokovan gospodarskom krizom, pad kupovne moći uzrokovan gospodarskom krizom,
- upravljanje i procesi: izostanak navodnjavanja u kritičnom razdoblju (suša), rizik menadžerske pogreške, značajne promjene u strukturi tla uzrokovane upotrebom teške mehanizacije (pr. zbijanje tla, ...), stari vinogradi u „lošoj kondiciji“, promjene u tehnologiji proizvodnje (zastarjela tehnologija, nedovoljno uvođenje nove tehnologije), nedovoljna kontrola kvalitete (propusti u kontroli kvalitete), promjena poslovne politike na orijentiranost na prinos, ovisnost o kooperantima, nelikvidnost poduzeća, zalihe vina, niska educiranost zaposlenika, manjak/višak zaposlenika, pogreške zaposlenika, bolovanja, smrt..., cjenovna nekonkurentnost, IT nesigurnost i industrijska špijunaža, politika i institucije: visoka cijena kapitala (visoke kamatne stope), promjenjivost kamatnih stopa, promjene poljoprivredne i trgovinskih politika

---

<sup>2</sup> Anketa dostupna na zahtjev autorici.

(EU, CEFTA,...), nesigurnosti regulatornih i zakonskih politika, društveno politička situacija (gospodarske sankcije, ...), nedovoljan nadzor tržišta, crno tržište,..., skupa i složena državna administracija, nedovoljne potpore za otežane uvjete gospodarenja.

Prema Meuwissenn i sur. (2001), strategije su grupirane u tri grupe, strategije izvan gospodarstva, strategije na gospodarstvu, i strategije prijenosa rizika:

- strategije izvan gospodarstva strategije: proizvodna diversifikacija tvrtke, korištenje programa potpore (nacionalni i EU programi),
- strategije na gospodarstvu: zemljopisna i vremenska diversifikacija proizvoda, pridržavanje tehnologije i agrotehničkih rokova, korištenje vlastitog zemljišta, navodnjavanje, protumrazni i protugradni sustav, zalihe rezervnih dijelova, lizing i/ili najam opreme i mehanizacije, sustav nabave i logistike (repromaterijal, ...), organizirana nabava *inputa*, prodaja proizvoda putem više različitih kanala, zalihe vina, zalihe gotovine i ostale rezerve u slučaju financijskih rizika, prodaja imovine, korištenje stručnih, konzultantskih usluga, ljudski potencijali (dovoljan broj radnika u „vrhovima“ proizvodnje), privremeno zapošljavanje, stalno učenje i informiranost (tečajevi, treninzi),
- strategije prijenosa rizika: *hedging*, faktoring, proizvodnja za poznatog kupca (robne marke,...), osiguranje (opreme, objekata...), prodajni ugovori, ugovori s kooperantima, konkurentsko udruživanje (klasteri - vertikalno i horizontalno).

Ispitanici su trebali ocijeniti vjerojatnost pojave pojedinih rizika u poslovanju. Navedene izvore rizika ispitanici su ocjenjivali prema Likertovoj ljestvici od 1 do 5, pri čemu je ocjena 1 pretpostavljala vjerojatnost pojave rizika manju od 10%, ocjena 2 pretpostavljala je vjerojatnost 11-30%, ocjena 3 vjerojatnost od 31-60%, ocjena 4 vjerojatnost od 61-90% dok je ocjena 5 pretpostavljala vjerojatnost pojave rizika od 90% i više.

Ispitanici su ocjenjivali i posljedice pojedinih rizika na njihovo poslovanje ocjenama, prema Likertovoj skali, od 1 do 5. Ocjena 1 pretpostavljala je zanemarivu posljedicu rizika, ocjena 2 umjerenu, ocjena 3 značajnu, ocjena 4 kritičnu i ocjena 5 pretpostavljala je katastrofalnu posljedicu nastanka rizika. Pri ocjenjivanju posljedica nastanka rizika opisi ocjena, zanemariva, umjerena, značajna, kritična, katastrofalna posljedica rizika, preuzeti su iz rada Jaffee i sur. (2010) u kojem je primijenjena bodovna ljestvica rizika.

U sljedećem pitanju ispitanicima je bilo ponuđeno nadopuniti i opisati rizike koji su izostavljeni te da ocijene vjerojatnost nastanka i posljedicu nastanka rizika. Prema radu Jaffee i sur. (2010) ispitanici su ocjenjivali grupe rizika koje u sljedećih 5 godina smatraju najvećim preprekama u poslovanju: prirodne nepogode/katastrofe (uključujući ekstremne

vremenske prilike), biologija i okoliš (štetnici i bolesti, zagađenost uvjetovana lošim sanitarnim uvjetima, ljudima ili bolestima, kontaminacije koje utječu na sigurnost hrane, prirodne resurse/okoliš, odnosno proizvodnju i preradu), tržište, upravljanje i procesi, politika i institucije).

Ispitanici su ocjenjivali važnost strategija u poslovanju i učestalost primjene strategija u svom poslovanju. Važnost primjene strategija općenito u poslovanju ocjenjivana je ocjenama na skali od 1 do 5, pri čemu je ocjena 1 pretpostavljala kategoriju uopće nije važno, 2 nije važna, 3 bez utjecaja, 4 važna, dok je ocjena 5 pretpostavljala kategoriju jako važne strategije.

U sljedećem pitanju ispitanici su zamoljeni za ocjenu učestalosti primjene navedenih strategija u svom poslovanju ocjenama od 1 do 5 pri čemu je ocjena 1 pretpostavljala da nikada ne primjenjuju ponuđenu strategiju, 2 rijetko, 3 ponekad, 4 često, i ocjena 5 pretpostavljala je da ispitanici uvijek primjenjuju ponuđenu strategiju.

Sljedeće pitanje uključivalo je razloge zašto se učestalije ne koriste ranije navedene strategije za upravljanje, posebno za kategorije nikada, rijetko i ponekad. Kao mogući razlozi navedeni su nedovoljna financijska sredstva, preopterećenost postojećih resursa, nemogućnost zapošljavanja eksperata odnosno na tržištu nema dovoljno eksperata, manjak vremena ili nedostatak znanja za primjenu strategija te je ostavljena mogućnost ispitanicima da naznače, ako postoji, neki drugi razlog.

Imajući u vidu strukturu izrade ankete prema Marušić i Vranešić (2001) posljednji dio obuhvatio je pitanja o strateškom upravljanju i strateškom upravljanju rizicima unutar tvrtke (ime tvrtke, strateško planiranje, strateško upravljanje rizicima, sustavi kvalitete) i "osobine ispitanika,, (radno mjesto, dob spol, obrazovanje).

Anketa je provedena u dvije faze, pilot ispitivanje (pre-test) i glavno istraživanje. U pilot ispitivanju (pretest) anketa je odasлана putem e-maila prema tri djelatnika znanstvenih institucija i prema jednom konzultantu. Gotovo su u potpunosti uvaženi komentari osoba koje su sudjelovale u pretestiranju. Nakon dorade pitanja, anketa je upućena na pilot istraživanje. Anketa za pilot istraživanje odasлана je e-mailom prema pet vinarija u Hrvatskoj. Povratne informacije primljene su od dvije vinarije koje nisu imale primjedbe već su ispunile anketu. Rezultati ankete pilot istraživanja pribrojeni su glavnom istraživanju. Anketa je provedena tijekom 2015. godine. U tijeku provođenja ankete poslana su tri podsjetnika prema ispitanicima. Odgovori u obje ankete obrađeni su pomoću statističkog softvera za statističku analizu, IBM SPSS Statistics 21.

- Normalnost distribucije

Normalno distribuirani podaci su podaci koji statistički bitno ne odstupaju, tj. proizlaze iz normalno distribuirane populacije. Postoje dvije vrste normalnosti: univarijatna i multivarijatna. Univarijatna normalnost odnosi se na pojedinačnu varijablu. Međutim, multivarijatna normalnost (kombinacija dviju ili više varijabli) znači da su pojedinačne varijable normalne u univarijantnom smislu i da je njihova kombinacija također normalno distribuirana (Hair i sur., 1998 iz Butigan, 2010).

- Indeks zaobljenosti i indeks asimetričnosti

Izračunavanje indeksa zaobljenosti i indeksa simetričnosti uobičajene su metode koje se koriste za ispitivanje devijacije normalnosti. Kod normalne distribucije vrijednost indeksa zaobljenosti i simetričnosti trebala bi biti 0. Ipak, stvarne vrijednosti indeksa zaobljenosti i simetričnosti nisu dovoljni pokazatelji. Umjesto toga, vrijednost se obično pretvara u z-score koji je jednostavan pokazatelj distribucije čija je srednja vrijednost 0 i standardna devijacija 1, koja se može pretvoriti od  $Z$  simetričnost = simetričnost/standardna pogreška simetričnosti ili  $Z$  zaobljenost = zaobljenost/ standardna pogreška zaobljenosti. Ako se uzimaju apsolutne vrijednosti (z-score) kod normalne distribucije, očekuje se da će biti oko 5% veće. Trebaju se dobiti apsolutne vrijednosti veće od  $\pm 1,96$  i 1% veće od  $\pm 2,8$  i niti jedna ne treba biti veća od 3,29. Izvan ovih raspona svaki se slučaj smatra *outlierom*. C.R. je kritični omjer koji predstavlja procjenu parametra podijeljenu s njenom standardnom greškom i djeluje kao z-score u testiranju da je procjena statistički različita od nule (Butigan, 2010).

- Analiza pouzdanosti

Pri odabiru ljestvica važno je da su ljestvice pouzdane. Jedan od najčešće korištenih indikatora unutarnje dosljednosti ljestvica jest Cronbach alpha koeficijent. Idealno bi, koeficijent Cronbach alpha ljestvice trebao biti veći od 0,7. Međutim, Cronbach alpha vrijednost dosta je osjetljiva na broj stavaka unutar ljestvice. Kod kratkih ljestvica (na primjer ljestvice s manje od deset stavaka) uobičajeno je da se mogu naći prilično niske Cronbach vrijednosti (na primjer 0,5) (Pallant, 2005). Prema DeVellis (1991) iz Kovačić i sur. (2013), od 0,65 do 0,70 je prihvatljiva pouzdanost, do 0,80 je vrlo dobra, do 0,90 odlična, dok za vrijednosti iznad 0,90 treba skratiti skalu.

#### 4.2.6. Financijska analiza

U procesu analize financijskih izvještaja moguće je koristiti se čitavim nizom različitih postupaka, koji su prije svega utemeljeni u raščlanjivanju i uspoređivanju. Horizontalnom analizom nastoji se uočiti tendencija i dinamika promjena pojedinih pozicija temeljnih financijskih izvještaja, a vertikalnom analizom omogućava se uvid u strukturu financijskih izvještaja (Žager i sur., 2008).

Bilanca je sustavni pregled imovine, obveza i kapitala na određeni datum. Kratkotrajna imovina je imovina za koju se očekuje da će se realizirati ili se drži za prodaju ili potrošnju u redovnom tijeku poslovanja, primarno se drži za trgovanje te se očekuje da će se realizirati unutar dvanaest mjeseci od datuma bilance, novac ili novčani ekvivalent, osim ako mu nije ograničena mogućnost razmjene ili upotrebe za podmirivanje obveza za razdoblje od najmanje dvanaest mjeseci od datuma bilance. Sva druga imovina je dugotrajna. Kratkoročne obveze su obveze za koje se očekuje da će se podmiriti u redovitom tijeku poslovnog ciklusa, primarno se drže radi trgovanja te dospijevaju za podmirivanje unutar dvanaest mjeseci poslije datuma bilance. Poduzetnik nema bezuvjetno pravo odgoditi podmirivanje obveza za najmanje dvanaest mjeseci poslije datuma bilance. Sve druge obveze su dugoročne. Račun dobiti i gubitka prikazuje prihode i rashode te dobit ili gubitak ostvaren u određenom obračunskom razdoblju (Bolfek i Stanić, 2011, Odbor za standarde financijskog izvještavanja, 2015).

Financijska analiza obuhvatila je horizontalnu i vertikalnu analizu financijskih podataka. U horizontalnoj analizi promatrani su financijski izvještaji (bilanca i račun dobiti i gubitka) u razdoblju od 2011. do 2015. godine. Kod vertikalne analize analizirana je struktura unutar financijskih izvještaja, posebno u dijelu imovine i obveza bilance. Financijska izvješća bila su osnova za analizu pokazatelja likvidnosti, zaduženosti, profitabilnosti i Altmanov A-Z-score.

Prema definiciji, koeficijent tekuće likvidnosti jest omjer kratkotrajne imovine i kratkoročnih obveza i u pravilu bi trebao biti veći od 2 (Žager i sur., 2008).

$$\text{Koeficijent tekuće likvidnosti} = \frac{\text{kratkotrajna imovina}}{\text{kratkoročne obveze}}$$

Koeficijent ubrzane likvidnosti jest omjer sume novca i potraživanja i kratkoročnih obveza. Uobičajeno se ističe kako bi njegova vrijednost trebala biti 1 ili veća od 1 (Žager i sur., 2008).

$$\text{Koeficijent ubrzane likvidnosti} = \frac{\text{novac u banci i blagajni} + \text{dugoročna} + \text{kratkoročna potraživanja}}{\text{kratkoročne obveze}}$$

Koeficijent financijske stabilnosti jest omjer dugotrajne imovine i sume kapitala i dugoročnih obveza. Ovaj pokazatelj po definiciji mora biti manji od 1 jer poduzeće dio svoje kratkotrajne imovine mora financirati iz kvalitetnih dugoročnih izvora tj. iz radnog kapitala. U izračunu je za radni kapital iz bilance primijenjena razlika kratkotrajne imovine i kratkoročnih obveza (Žager i sur., 2008).

$$\text{Koeficijent financijske stabilnosti} = \frac{\text{dugotrajna imovina}}{\text{radni kapital} + \text{dugoročne obveze}}$$

Od pokazatelja zaduženosti analiziran je koeficijent zaduženosti. Koeficijent zaduženosti pokazuje do koje mjere poduzeće koristi zaduživanje kao oblik financiranja, odnosno koji je postotak imovine nabavljen zaduživanjem. Što je veći odnos duga i imovine, veći je financijski rizik, a što je manji odnos, niži je financijski rizik. U pravilu bi vrijednost koeficijenta zaduženosti trebala biti 50% ili manja (Šarlija, 2009). Koeficijent zaduženosti jest omjer ukupnih obveza i ukupne imovine (Šarlija, 2009; Šarlija i sur. 2009).

$$\text{Koeficijent zaduženosti} = \frac{\text{kratkoročne} + \text{dugoročne obveze}}{\text{ukupna imovina}}$$

Od pokazatelja profitabilnosti analizirana je stopa povrata imovine (ROA) i stopa povrata glavnice (ROE). ROA jest omjer neto dobiti i ukupne imovine. Opće pravilo glasi da sve vrijednosti pokazatelja ispod 5% podrazumijevaju visok stupanj intenzivnosti imovine, dok vrijednosti iznad 20% označavaju nisku intenzivnost imovine (<http://beginnersinvest.about.com> iz Šarlija, 2009).

$$\text{ROA} = \frac{\text{dobit ili gubitak razdoblja}}{\text{ukupna aktiva}}$$

Na temelju indikatora ROE moguće je ocijeniti daje li investirani kapital dovoljne prinose s obzirom na vezani rizik (Novotná i Svoboda, 2014). ROE pokazuje koliko novčanih jedinica dobiti poduzeće ostvaruje na jednu jedinicu vlastitog kapitala. Ukoliko su stope

profitabilnosti vlastitog kapitala vrlo visoke, pa čak i više od stopa profitabilnosti imovine, poduzeću bi se isplatilo koristiti tuđim kapitalom, i obrnuto (Buble i sur., 2005, iz Šarlija, 2009). Financijska poluga povoljno djeluje na poslovanje poduzeća u situaciji kada je rentabilnost vlastitoga kapitala veća od rentabilnosti imovine (Ježovita i Žager, 2014). Ekonomski efekt posuđivanja je pozitivan dok god je rentabilnost ukupne imovine veća od troška posuđivanja. Poduzeća koja nemaju adekvatne povrate za plaćanje troška kamata, zaduživanjem smanjuju rentabilnost vlastitoga kapitala (Palepu i sur., 2007, iz Ježovita i Žager, 2014).

$$ROE = \frac{\text{dobit ili gubitak razdoblja}}{\text{kapital i rezerve}}$$

– Altmanov Z-score model

Edward I. Altman proveo je prvo multivarijantno istraživanje odnosa financijskih pokazatelja i vjerojatnosti za stečaj, čijim je istraživanjem nastao model nazvan Altman Z-score. Z-score je sintetički pokazatelj koji predviđa stečaj poduzeća u roku od jedne ili dvije godine (Žager i sur., 2008).

U radu je primijenjen Model A-Z-score model koji je postavljen samo za proizvodna poduzeća,

$$A \text{ model } Z = 0,717X_1 + 0,847X_2 + 3,107X_3 + 0,42X_4 + 0,998X_5$$

pri čemu je  $X_1$  = radni kapital/ukupna imovina,  $X_2$  = zadržana dobit/ukupna imovina,  $X_3$  = dobit prije kamata i poreza (EBID)/ukupna imovina,  $X_4$  = knjigovodstvena vrijednost poduzeća/ukupne obveze,  $X_5$  = ukupni prihodi/ukupna imovina. Z-score je sintetički pokazatelj koji predviđa stečaj poduzeća u roku od jedne ili dvije godine. Vrijednost skupnog pokazatelja Z-score modela kreće se u granicama od -4 do 8 pri čemu se distinkcija triju modela sastoji u granicama vjerojatnosti odlaska u stečaj. Poduzeća čiji je Altmanov pokazatelj veći od 3 mogu se okarakterizirati kao financijski zdrava poduzeća (Žager i sur., 2008):

Z-score model	Raspon ocjene (od -4,0 do +8,0) - rizik stečaja			
	Vrlo mali	"Sivo područje"		Vrlo veliki 95%
		Zabrinutost	U roku 2 godine	
Originalni	$\geq 3,0$	2,99-2,79	2,78-1,81	1,80 $\geq$
<b>Model A</b>	<b><math>\geq 2,9</math></b>	<b>2,89-2,69</b>	<b>2,68-1,24</b>	<b>1,23<math>\geq</math></b>
Model B	$\geq 2,6$	2,59-2,39	2,38-1,11	1,10 $\geq$

Shema 3: Vrijednost skupnog pokazatelja Z-score

Izvor: Žager i sur. (2008)

Za knjigovodstvenu vrijednost poduzeća primijenjen je izračun iz rada Aralice (2005), (Bendeković, 1991, FOIP, 2001, iz Aralice, 2005),

$$V_k = I_k - O_k,$$

pri čemu je  $V_k$  = knjigovodstvena vrijednost predmeta analize,  $I_k$  = knjigovodstvena vrijednost imovine u bilanci stanja poduzeća,  $O_k$  = knjigovodstvena vrijednost obveza u bilanci poduzeća.

Za ukupne obveze primijenjena je suma dugoročnih i kratkoročnih obveza.

Vrijednost modela A-Z-score-a primijenjena je za rangiranje vinarija koje se razlikuju u izloženosti riziku (visoko, srednje i niskorizične), prema sljedećim kriterijima:

Z-score model	Raspon ocjene (od -4,0 do +8,0) - rizik stečaja			
	Vrlo mali	„Sivo područje“		Vrlo veliki 95%
		Zabrinutost	U roku 2 godine	
Model A	$\geq 2,9$	2,89-2,69	2,68-1,24	1,23 $\geq$
Ocjena	1	2		3
Opis	Niskorizične vinarije	Srednjerizične vinarije		Visokorizične vinarije

Shema 4: Rangiranje poduzeća prema vrijednost skupnog pokazatelja Z-score

Izvor: prilagođeno iz Žager i sur. (2008)

U izradi modela hipotetske vinarije promatrana je vrijednost EBIT, čiji je izračun dobiven razlikom EBITDA i amortizacije. Vrijednost EBITDA razlika je poslovnih prihoda i poslovnih rashoda. Zaduženost je izračunata u omjeru ukupnih obveza (dugoročnih i kratkoročnih) i ukupne aktive i omjera ukupnih obveza (dugoročnih i kratkoročnih) i kapitala i rezervi. U izračunu ROA izračunan je omjer neto dobiti i sume kratkotrajne i dugotrajne imovine. Za Altmanov A-Z-score korišten je izračun za X1 izračunan je omjer razlike kratkotrajne imovine i kratkoročnih obveza i sume kratkotrajne i dugotrajne imovine, a za X2 umjesto zadržane dobiti primijenjen je omjer dobiti nakon poreza i sume dugotrajne i kratkotrajne imovine. U izračunu X3 izračunan je omjer EBIT-a i sume dugotrajne i kratkotrajne imovine. Za X4 izračunan je omjer kapitala i rezervi i sume dugoročnih i kratkoročnih obveza i za X5 omjer poslovnih prihoda i sume dugotrajne i kratkotrajne imovine.



## 5. REZULTATI ISTRAŽIVANJA

### 5.1. Obilježja proizvodnje i tržišta grožđa i vina

Vinogradarske površine u svijetu se od 2000. do 2011. godine smanjuju. Promatrajući 2011. i 2000. vinogradarske površine smanjile su se za 4,46%, dok se svjetska proizvodnja vina smanjila za 4,29%. U istom razdoblju potrošnja vina povećana je za 7,52% (tablica 2). Prema OIV-u (2016), od završetka programa Europske unije (berbe 2011/2012) kojim je reguliran proizvodni potencijal u EU-u (Uredba Komisije, 479/2008 od 29.04.2008.) stopa smanjenja vinograda značajno je usporena.

Europa je još uvijek najveće tržište potrošnje vina, proizvodnje i izvoza. Najvažnija tri svjetska konkurenta su Italija, Francuska i Španjolska i sa svojom stoljetnom vinogradarskom tradicijom i dalje predstavljaju „referentnu točku“ za svjetsku proizvodnju vina (Lombardi i sur., 2016).

Tablica 2: Vinogradarske površine, proizvodnja, potrošnja i trgovina vina u svijetu

Opis	Svjetske površine vinograda (kha)	Svjetska proizvodnja vina (Mhl)	Svjetska potrošnja vina (Mhl)	Svjetska trgovina vina prema vrijednosti (bn EUR)	Svjetska trgovina vina prema količinama (Mhl)
2000.	7.847	280	226	12	60
2001.	7.873	266	228	12	65
2002.	7.877	257	230	15	68
2003.	7.884	264	237	15	72
2004.	7.828	296	237	15	77
2005.	7.770	278	237	16	79
2006.	7.734	283	245	18	84
2007.	7.658	268	250	20	89
2008.	7.576	269	250	20	90
2009.	7.535	272	242	18	88
2010.	7.512	264	241	21	96
2011.	7.485	267	243	23	103
2012.	7.487	258	244	25	104
2013.	7.538	289	243	26	101
2014.	7.541	269	239	26	102
2015.	7.534	274,4	240	28,3	104,3
Indeks 2015./2000.	96,01	98,00	106,19	235,83	173,83

kha: tisuća hektara, Mhl: milijuna hektolitara, bn: bilijuna

Izvor: The International Organisation of Vine and Wine (2016), obrada autora


Prema podacima Eurostata, od 2005. do 2015. Njemačka je zabilježila najmanji pad u proizvodnji vina od -8,04%. Prema količini konačnih zaliha Francuska ima najveći pad zaliha (-16,98%). Najviša razina samodostatnosti bila je u Italiji 2009. godine (178,84%), Španjolskoj (171,08%), Bugarskoj (152,12%) i Mađarskoj (146,02%) (tablica 3, prilog 4, prilog 6).

Tablica 3: Vodeće zemlje Europe u proizvodnji vina (1.000 hl)

Opis	2005.	2007.	2009.	2011.	2013.	2015.	Indeks 2015./ 2005.
Francuska	58.845	53.025	42.806	45.373	41.363	47.423	80,59
Italija	53.135	49.631	46.245	46.734			
Španjolska	50.062	43.676	41.583	40.892	35.778	45.015	89,92
Njemačka	10.107	9.000	10.089	6.976	9.102	9.294	91,96
Portugal	7.481	7.542	5.620	7.148	6.308	6.202	82,90

Izvor: Eurostat (2016, a), 2005. - 2015., obrada autora

Najveća količina ukupne domaće potrošnje zabilježena je u Francuskoj 2015. godine od 37.300.000 hl. Prema potrošnji vina po stanovniku u 2015. godini zabilježena je najveća potrošnja u Luksemburgu (graf 1).



Graf 1: Ukupna potrošnja vina po stanovniku

Izvor: Eurostat (2016, a), 2005. - 2014.

Prema dostupnim podacima od 2008. do 2014. godine, Španjolska je imala najveći broj poduzeća, 3.709 u 2015. godini, dok se najveći rast u broju poduzeća dogodio u Portugalu (tablica 4).

Tablica 4: Broj poduzeća prema proizvodnji vina od grožđa

Opis	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	Indeks 2015./2008.
Španjolska	3.704	3.428	3.613	3.705	3.724	3.656	4.059	3.709	100,13
Italija	1.785	1.775	1.795	1.829	1.829	1.843	2.007	1.974	110,59
Francuska	1.874	1.470	1.400	1.445	1.623	1.481	1.275	1.741	92,90
Portugal	785	823	819	841	850	1.022	1.226	1.297	165,22
Mađarska	941	920	882	911	887	882	881	871	92,56

Izvor: Eurostat (2017, b), 2008. - 2015., obrada autora

Prema vrijednosti proizvodnje vina od grožđa, u 2015. godini, poduzeća u Francuskoj imala su najveću vrijednost proizvodnje (10.508 mil. EUR) (tablica 5).

Tablica 5: Vrijednost proizvodnje vina od grožđa (milijuni EUR)

Opis	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	Indeks 2015./2008.
Francuska	9.224	7.572	7.499	8.778	9.889	10.104	9.777	10.508	113,92
Italija	7.133	6.210	6.933	9.026	8.039	8.335	8.910	9.018	126,44
Španjolska	5.985	5.105	5.301	5.979	6.208	6.342	6.127	6.238	104,23
Njemačka	1.940	1.934	1.924	1.955	2.057	2.054	2.037	1.867	96,24
Portugal	1.252	1.234	1.299	1.243	1.301	1.380	1.436	1.517	121,20

Izvor: Eurostat (2017, b), 2008. - 2015., obrada autora

Potrošačke cijene vina razlikuju se od zemlje do zemlje, općenito od najviših cijena u Kini do najnižih cijena u Njemačkoj. Cijene vina u boci zapremine 0,75 l u različitim zemljama razlikuju se ovisno o porezima i ostalim obvezama te o odluci uvoznika ili distributera o cijeni (marži) vina (tablica 6).

Tablica 6: Cjenovni razredi vina (pakovine 0,75 l, EUR/l)

Opis	Srednja razina			Gornja razina
	Trgovački premium	Super premium	Ultra premium	
≤ 4,99	5,00 – 9,99	10,00 – 14,99	15,00-49,99	50,00 i više

Izvor: COGEA S.R.L. (2014)

Cijene vina zapremine od 1,5 do 5 litara mogu se svrstati u četiri razine. Prva su razina vina jeftinija od 3 EUR/l, nakon toga su vina cijene od 3 do 4,9 EUR/l, vina od 5 do 9,9 EUR/l i vina skuplja od 10 EUR/l. Kod konkurentskog pozicioniranja europskih mirnih vina s obzirom na omjer cijene i kvalitete, u razdoblju od 2000. do 2012., sugerira se da su vina EU-a u buteljama bolje kvalitete od konkurentskih vina Novog svijeta, i obrnuto, niže su kvalitete vina u rinfuzi, u izvozu. Novi Zeland i Francuska bilježe najviše cijene (za bocu i za rinfuzu), dok Španjolska ima jedne od najnižih. Mirna vina EU-a većinom su izgubila tržišni udio od glavnih konkurenata na svjetskom tržištu između 2000. - 2005/06. Nakon toga se tržišni udio EU-a stabilizirao na oko 68% vrijednosnog i 65% količinskog udjela. Analiza je pokazala da se nakon 2007. mijenja strategija izvoza nekih zemalja Novog svijeta (Australija, SAD, Južna Afrika, Novi Zeland), postupnom zamjenom vina u buteljama s vinom u rinfuzi. Za razliku od tržišta EU-a (niži cjenovni razredi u Njemačkoj i unutar srednjeg cjenovnog razreda u Danskoj i Velikoj Britaniji), europska vina češće su pozicionirana na tržištima trećih zemalja u višem cjenovnom razredu (Ultra premium i gornjoj razini) (COGEA S.R.L., 2014).

Trgovina u EU-u ima karakteristična obilježja koja je razlikuju od svjetske trgovine vina. Prvo, snažan utjecaj udaljenosti na trgovinu vina rinfuze EU-a koji je u suprotnosti s uobičajenom procjenom međunarodne trgovine. Naime, u EU-u prijevoz vina rinfuze obavlja se cestovnim putem, a taj trošak ima veći utjecaj na proizvode niže vrijednosti. Na međunarodnoj razini, glavnina vina (rinfuze) prevozi se na velikim udaljenostima morem, s relativno malim utjecajem na jediničnu cijenu. Kao drugo, čini se da domaća ponuda vina nema nikakvog utjecaja na izvoz vina. U slučajevima vrlo bogatih berbi od tržišta vina izvan EU-a očekuje se apsorpiranje viška vina EU-a (Lombardi i sur., 2016).

U svijetu su dvije krajnje situacije vezane za koncentraciju vinskih poduzeća. Stupanj koncentracije izražava se indikatorom C4, tržišnim udjelom top četiri poduzeća. S jedne strane u Rusiji je najniža koncentracija vinskih poduzeća ( $C4 = 5,3\%$ ); i s druge strane, u SAD-u, najviši C4 (49,2%). U Kini, Njemačkoj i SAD-u, četiri vodeća poduzeća domaće su vinarije. Među „velikim igračima“, čileanska Concha y Toro je s velikom učestalošću među vodeće četiri vinarije (u Danskoj, Japanu, Rusiji i Velikoj Britaniji). Osim u Njemačkoj, europske vinarije nalaze se među vodeće četiri u samo dvije zemlje (Danska i Hong Kong). Uočena su problematična područja konkurentnosti vina EU-a: pristup tržištu, proces donošenja odluka poslovnih subjekata, usvajanje proizvoda na tržištima (COGEA S.R.L., 2014).

Državni zavod za statistiku Republike Hrvatske za 2015. godinu zabilježio je ukupne površine korištenoga poljoprivrednog zemljišta od 1.537.629 ha, od čega su 25.587 ha vinogradarske površine. U razdoblju od 2000. do 2015. godine prosječni udio vinogradarskih površina u ukupnim poljoprivrednim površinama je 2,28% (tablica 7).

Tablica 7: Površine poljoprivrednog zemljišta, vinograda, proizvodnja grožđa, vina i prinos u Republici Hrvatskoj

Opis	Korištena poljoprivredna površina (ha)	Površine vinograda (ha)	Proizvodnja grožđa (t/ha)	Proizvodnja vina (tis. hl)	Prinos grožđa (t/ha)
2005.	1.210.790	29.670	181.021	1.248	6,1
2006.	1.230.183	30.766	179.426	1.237	5,8
2007.	1.201.756	32.454	197.979	1.365	6,1
2008.	1.289.091	33.741	185.256	1.278	5,5
2009.	1.299.582	34.380	206.437	1.424	6,0
2010.	1.333.835	32.709	207.743	1.433	6,4
2011.	1.326.083	32.485	204.373	1.409	6,3
2012.	1.330.973	29.237	187.550	1.293	6,4
2013.	1.568.881	26.100	181.096	1.249	6,9
2014.	1.508.885	26.164	134.941	842	5,2
2015.	1.537.629	25.587	154.227	992	6,0
Indeks 2015./2005.	126,99	86,24	85,20	79,49	98,36

Izvor: Državni zavod za statistiku 2005. - 2015., obrada autora

Prema podacima Državnog zavoda za statistiku Republike Hrvatske od 2005. do 2015., u 2005. godini zabilježena je proizvodnja od 1.248.000 hl, a u 2015. proizvodnja od 992.000 hl što je pad proizvodnje od -20,51%. Prinosi grožđa u istom razdoblju smanjeni su za 1,64%, sa 6,10 t/ha u 2005. na 6 t/ha u 2015. godini (tablica 7).

U sustavu zaštite zemljopisnog podrijetla u 2014. godini upisano je 1.333 proizvođača i 4.839 vina. U 2015. zabilježen je domaći promet vina od 488.878,17 hl te drugih proizvoda od grožđa i vina (voćna vina, voćni ocat i drugi proizvodi) od 92.121,52 hl. U prometu vina domaće proizvodnje, temeljem Rješenja za promet vina, koji ne uključuje uvoz vina putem rinfuze ili putem uvoza vina u boci, u 2015. u odnosu na 2011. godinu i promet vina došlo je do smanjenja u prometu vina od -6,69% (Hrvatski centar za poljoprivredu, hranu i selo, 2017, a) (tablica 8).

Tablica 8: Promet vina prema kategorijama kakvoće u Republici Hrvatskoj (hl)

Opis	Domaća proizvodnja					Indeks 2015./ 2011.
	2011.	2012.	2013.	2014.	2015.	
Stolno*	159.715,48	195.591,86	149.757,02	151.007,66	120.498,24	75,45
Kvalitetno	333.141,10	324.384,87	329.153,16	391.265,92	331.997,26	99,66
Vrhunsko	26.693,21	26.716,12	23.302,00	29.389,29	31.625,69	118,48
Pjenušavo biser gazirano	3.599,00	2.480,90	2.247,70	2.965,26	4.251,38	118,13
Specijalno **	794,03	1.303,10	2.432,80	888,75	505,60	63,68
Ukupno	523.942,82	550.476,85	506.892,68	575.516,88	488.878,17	93,31

Napomena: \*Stolno vino bez ZOI-a, sa ZOI-em, s KZP-om, \*\*Specijalno (desertno, aromatizirano, likersko)

Izvor: Hrvatski centar za poljoprivredu, hranu i selo (2017, a), obrada autora

Prema podacima Državnog zavoda za statistiku Republike Hrvatske (2015) i bilanci vina Hrvatska je bila samodostatna vinima u vinarskoj godini 2001./2002. (101,17%), 2006./2007. (113,33%) i 2007./2008. (122,72%). Najniža razina samodostatnosti zabilježena je 2014./2015. godine sa 72,66%. U bilanci vina, u potrošnji vina najniža razina potrošnje za ljudsku prehranu po stanovniku bila je 2007./2008. od 21,49 litara (bruto), dok je najviša razina zabilježena 2012./2013. od 38,85 litara (bruto) (tablica 7).

Prema pregledu izvoza vina iz Republike Hrvatske u 2013. godini zabilježena je najveća vrijednost izvoza (tablica 9).

Tablica 9: Izvoz vina iz Republike Hrvatske prema količini i vrijednosti

Opis	Količina (hl)	Vrijednost (HRK)	Vrijednost (EUR)	Vrijednost /Količina HRK/hl
2011.	38.461	76.034.043	10.218.659	1.977
2012.	57.841	93.160.435	12.402.705	1.611
2013.	30.185	78.790.433	10.412.348	2.610
2014.	36.592	89.633.935	11.738.816	2.450
2015.	49.401	94.348.009	12.405.263	1.910
Indeks 2015./2011.	128,44	124,09	121,40	96,61

Izvor: Državni zavod za statistiku Republike Hrvatske, 2011. - 2015., obrada autora

Uspoređujući omjer vrijednosti i količine zamjetno je da je u 2012. godini uvezena vrijednosno najniža količina vina u razdoblju od 2011. do 2015. godine (tablica 10).

Tablica 10: Uvoz vina u Republiku Hrvatsku prema količini i vrijednosti

Opis	Količina (hl)	Vrijednost (HRK)	Vrijednost (EUR)	Vrijednost /Količina HRK/hl
2011.	145.981	117.976.340	15.828.309	808
2012.	145.385	108.361.620	14.419.876	745
2013.	131.764	124.446.935	16.452.460	944
2014.	223.947	183.997.487	24.123.002	822
2015.	290.059	220.663.079	28.992.401	761
Indeks 2015./2011.	198,70	187,04	183,17	94,18

Izvor: Državni zavod za statistiku Republike Hrvatske, 2011. - 2015., obrada autora

U Republici Hrvatskoj došlo je do disperzije domaćih vinarija. U prometu vina 2004. sudjelovalo je 936 proizvođača. Samo 33 vinarije, kao vodeće vinarske kuće, ostvarile su 79% od ukupnog prometa vina (Milat, 2005).

Tijekom 2011. godine u prometu vina sudjelovalo je 1.172 poslovnih subjekata, 33 vinarije ostvarile su 76,23% od ukupnog prometa vina domaće proizvodnje. U 2015. godini od 1.305 vinarija u prometu 33 vinarije ostvarile su 70,53% od ukupnog prometa vina (Hrvatski centar za poljoprivredu, hranu i selo, interni podaci, 2017, b).

Prema dostupnim podacima Državnog zavoda za statistiku Republike Hrvatske i godišnjim strukturno-poslovnim pokazateljima poduzeća iz grupe proizvodnje vina od grožđa, u razdoblju od 2011. do 2014. godine povećao se broj poduzeća za 5,18%, dok su se smanjili troškova osoblja (-20,98%), broj zaposlenih osoba (-19,11%) i broj plaćenih zaposlenika (-20,01%). U promatranom razdoblju vrijednost prometa smanjila se za 17,50 % i vrijednost proizvodnje za 14,04%. U istom razdoblju povećala se kupnja roba i usluga za daljnju prodaju, sa 164.734 na 170.028, te se smanjila kupnja energetskih proizvoda za 6,06% (tablica 11).

Tablica 11: Godišnji strukturno-poslovni pokazatelji poduzeća prema NKD-u 2007. za djelatnosti industrije, proizvodnju vina od grožđa u Republici Hrvatskoj

Opis	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	Indeks 2015./ 2008.
Broj poduzeća	254	288	323	309	317	314	325	321	126,38
Promet	782.421	854.938	1.058.160	1.077.141	1.012.795	894.810	888.625	971.600	124,18
Vrijednost proizvodnje	901.182	932.207	1.023.830	1.033.882	859.674	851.642	888.691	857.647	95,17
Kupnja roba i usluga za daljnju prodaju	12.815	55.843	144.106	164.734	173.190	178.554	170.028	204.364	1.594,72
Troškovi osoblja	181.373	223.237	268.695	258.306	222.292	203.890	204.105	210.144	115,86
Broj zaposlenih osoba	2.238	2.911	3.557	3.438	3.129	2.691	2.781	2.672	119,39
Broj plaćenih zaposlenika	2.032	2.683	3.338	3.234	2.923	2.505	2.587	2.474	121,75
Kupnje energetskih proizvoda	23.702	26.418	35.613	35.927	34.272	33.924	33.749	33.044	139,41

Napomena: Vrijednost izražena u tis. HRK

Izvor: Državni zavod za statistiku Republike Hrvatske, Strukturno-poslovne statistike poduzeća, 2011. - 2014., obrada autora



U Republici Hrvatskoj prema podacima Agencije za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju u 2015. godini zabilježeno je 41.175 poljoprivrednih gospodarstava u vinogradarskom registru i 20.881,77 ha (tablica 12).

Tablica 12: Struktura gospodarskih subjekata prema vrsti pravno-organizacijskog oblika subjekta i broju vinogradarskih parcela u Republici Hrvatskoj

Opis	2011.	2012.	2013.	2014.	2015. (22.9.)	Indeks 2015./ 2011.
OPG	79.749	79.591	79.270	79.653	40.308	50,54
Obrt	1.878	1.940	2.010	1.983	505	26,89
Ostali	45	61	62	60	22	48,89
Trgovačko društvo	1.942	1.992	2.082	2.090	307	15,81
Zadruga	149	149	158	155	33	22,15
Ukupno broj parcela	83.763	83.733	83.582	83.941	41.175	49,16

Napomena: Kategorija „Ostalo“ su škole, kaznionice i druge ustanove.

Izvor: Agencija za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju (2016), obrada autora

Ukupna vrijednost prodanih proizvoda (mirna, pjenušava i specijalna vina, mošt) u 2015. godini iznosila je 615.033.000 HRK, dok je u 2005. godini iznosila 661.188.000 HRK. Cijena vina porasla je sa 14,83 HRK/l na 16,95 HRK/l (tablica 13).

Razlog nižih prosječnih cijena vina u 2015. godini u odnosu na 2014. je „lošija“ berba grožđa 2015., kao i kvaliteta vina te je vino prodavano po nižoj cijeni. Drugi je razlog bio veći uvoz vina u 2015. s obzirom na 2014., a koje se prodavalo po nižoj cijeni od vina domaće proizvodnje (Državni zavod za statistiku Republike Hrvatske, 2017).

Prosječne proizvođačke cijene jesu cijene u koje su uključeni porezi (osim PDV-a), a isključene su subvencije i ostali novčani poticaji. Prosječna proizvođačka cijena za stolno vino je tijekom razdoblja oscilirala, od najniže u 2006. od 5,75 HRK/l do 7,86 HRK/l u 2015. godini. Prosječna proizvođačka cijena za grožđe kretala se od 4,56 HRK/kg u 2014. do 6,91 HRK/kg u 2008. (tablica 14).

Tablica 13: Proizvedene, prodane količine, vrijednost i cijena mirnih, specijalnih, pjenušavih vina i mošta u RH

Opis	Proizvedene količine proizvoda (hl)	Ukupne količine prodanih proizvoda (hl)	Ukupna vrijednost prodanih proizvoda (HRK)	Jedinična cijena (HRK/l)
2005.	498.820	445.836	661.188	14,83
2006.	531.204	460.484	660.985	14,35
2007.	583.688	419.291	672.067	16,03
2008.	508.691	410.520	682.770	16,63
2009.	555.678	394.816	620.610	15,72
2010.	462.814	400.495	613.432	15,32
2011.	428.847	374.877	574.359	15,32
2012.	373.116	369.069	582.307	15,78
2013.	460.881	435.939	645.189	14,80
2014.	400.666	377.394	617.180	16,35
2015.	406.592	362.781	615.033	16,95
Indeks 2015./2005.	81,51	81,37	93,02	114,32

Napomena: „Prodcom“ istraživanje zbrojeno za vlastit račun i na osnovi ugovora za mirna, specijalna, pjenušava vina i mošt. Izračun jedinične cijene količnik je vrijednosti prodanih proizvoda i ukupnih količina prodanih proizvoda.

Izvor: Državni zavod za statistiku Republike Hrvatske 2005. - 2015., (2015, 2017, a, b, c), obrada autora

Tablica 14: Prosječne proizvođačke cijene vina i grožđa u RH iz vlastite proizvodnje

Opis	Cijena za kvalitetno vino (HRK/l)	Cijena za stolno vino (HRK/l)	Cijena za grožđe (HRK/kg)
2005.	17,53	6,24	6,08
2006.	20,31	5,75	6,19
2007.	22,65	6,89	5,88
2008.	20,11	7,11	6,91
2009.	21,33	7,33	5,42
2010.	17,98	7,23	5,34
2011.	17,24	6,95	5,43
2012.	16,26	7,06	5,09
2013.	17,94	7,39	4,82
2014.	-	6,73	4,56
2015.	-	7,86	4,63

Napomena: Cijena vina odnosi se samo na vino dobiveno od grožđa iz vlastite proizvodnje.

U 2014. i 2015. godini nije bilo dostupnih podataka za cijenu kvalitetnog vina.

Izvor: Državni zavod za statistiku Republike Hrvatske 2005. - 2015.

Podaci govore o trendu smanjenja vinogradarskih površina (-3,04% u 2015./2005.) i proizvodnje vina (-1,29% u 2015./2005.) u svijetu. U 2015. godini u odnosu na 2005. vinogradarske površine u Hrvatskoj smanjene su za 13,76%, proizvodnja grožđa za 14,80% i proizvodnja vina za 20,51%.

U razdoblju 2015./2011. svjetska trgovina prema količinama povećala se za 23,04%, dok je povećanje svjetske trgovine vina prema vrijednosti nešto manje (+1,26%). Izvoz vina iz Hrvatske prema količinama povećao se za 28,44%, dok se prema vrijednosti u eurima, povećao za 21,40%. Uvoz vina u Hrvatsku povećao se za 98,70%, dok se prema vrijednosti povećao za 83,17%.

Potrošnja vina u svijetu u usporedbi 2015./2005. povećala se za 1,27%. Slično je stanje i u Hrvatskoj. U Hrvatskoj se potrošnja vina za ljudsku prehranu (bruto) povećala za 1,04%, a potrošnja za ljudsku prehranu po glavi stanovnika (bruto) povećala se za 5,83%.

Prema izvješću Europske komisije u 2015. godini u Europskoj uniji poslovalo je oko 23 milijuna malih i srednjih poduzeća, koja su zapošljavala 90 milijuna djelatnika (67% ukupne zaposlenosti) i generirala 3.900 milijardi eura dodane vrijednosti (57% ukupne dodane vrijednosti). U odnosu na 2014. godinu zaposlenost u europskim malim i srednjim poduzećima porasla je za 1,5%, a dodana vrijednost za 5,7%. Porast zaposlenosti u malim i srednjim poduzećima zabilježile su u 2015. godini sve članice EU-a, izuzev Finske. U Hrvatskoj u 2015. godini posluje 106.221 mikro, malih i srednjih poduzeća (99,7% ukupno registriranih poduzeća), koja ostvaruju udio od 54% u ukupnom prihodu, 69,2% u zaposlenosti i 50,3% u izvozu Hrvatske i po sva ova tri ključna kriterija u 2015. godini jačaju svoj udio i utjecaj na gospodarstvo Hrvatske u odnosu na prethodnu godinu. Izvještaj Europskog semestra o stanju gospodarstva u Hrvatskoj iz 2016. godine konstatira da je u 2015. godini Hrvatska izašla iz 6-godišnje krize, s rastom BDP-a od 1,8%. U razdoblju od 2008. do 2014. godine realni BDP smanjio se za više od -12%, a nezaposlenost se povećala s manje od 9% na više od 17% (Alpeza i sur., 2017).


Broj poduzeća u proizvodnji vina od grožđa u usporedbi 2014./2011. povećava se u Španjolskoj (+9,55%), Italiji (+9,73%), Portugalu (+56,98%), Njemačkoj (+24,07%), a smanjuje se u Francuskoj (-11,76%). U Hrvatskoj se broj poduzeća povećao za 5,18%.

Vrijednost proizvodnje vina od grožđa raste u Francuskoj (+11,38%), Španjolskoj (+2,48%), Njemačkoj (+4,19%) i Portugalu (+20,98%), a pada u Italiji (-1,29%). U Hrvatskoj je vrijednost proizvodnje pala za 14,04%.

### 5.1.1. Percepcija poslovnog okruženja vinarija u Hrvatskoj

U provedenoj anketi eksperata vinarstva od odaslanih 38 anketa povratno je zaprimljeno 26 odgovora, od čega je 25 odgovora korišteno u daljnjoj obradi. Nakon obavljene logičke kontrole anketnih podataka odgovori su šifrirani i uneseni za daljnju obradu.

Prema strukturi ispitanika, u anketi je sudjelovao najveći broj ispitanika iz javnih (36%) i znanstvenih (24%) institucija (graf 2).



Graf 2: Struktura ispitanika (n = 25)

Ispitanici su u anketi ocjenjivali snage, slabosti, prilike i prijetnje vinarija i vinarskog sektora Republike Hrvatske.

U setu pitanja vezanih za snage sektora eksperti su ocijenili turizam (srednja vrijednost 4,20) i vrhunske položaje (srednja vrijednost 4,12) najvažnijima za sektor, nakon kojih slijede okolišni uvjeti za proizvodnju vina (srednja vrijednost 4,00), autohtone sorte vinove loze (srednja vrijednost 3,80) i tradicija (srednja vrijednost 3,68). Kod pitanja o vrhunskim vinogradarskim položajima zabilježeno je najmanje odstupanje od srednje vrijednosti ili najniža standardna devijacija od 0,83 (prilog 9).

Za najvažnije slabosti ispitanici su izdvojili male usitnjene površine, neorganiziranost vinogradara i nedostatak marketinga vina (srednja vrijednost 4,20). U dijelu pitanja vezanih za slabosti sektora, najmanje rasipanje odgovora (standardna devijacija od 0,78) bilo je kod pitanja o cjenovnoj ne konkurentnosti, koja je ocjenjena s prosječnom vrijednosti 4,12 (prilog 10).


Kod pitanja o prilikama sektora, stručnjaci smatraju nove tehnologije (srednja vrijednost 2,00), razvoj agro- i vinskog turizma (srednja vrijednost 2,04) i porast turističke potražnje (srednja vrijednost 2,16) te porast potražnje za posebnim vinima, vrhunske kakvoće, autohtone sorte, ekološku proizvodnju (srednja vrijednost 2,16) najvažnijim prilikama sektora, dok nove oblike prodaje - web prodaja i važnost ekološkog uzgoja (srednja

vrijednost 3,04) te regulaciju tržišta u EU-u (srednja vrijednost 2,84) smatraju najmanje važnim prilikama. Najmanje rasipanje ocjena bilo je kod pitanja regulacije tržišta vina u EU-u (standardna devijacija 0,69) (prilog 11).


Stručnjaci smatraju crno tržište i nedostatak inspekcije (srednja vrijednost 2,16), ponudu vina iste kvalitete ali nižih cijena (srednja vrijednost 2,20), neplaćanje i nelikvidnost (srednja vrijednost 2,28) za najvažnije prijetnje, a promjene strukture i teksture tla korištenjem teške mehanizacije (srednja vrijednost 3,56), masovni turizam, onečišćenje okoliša (srednja vrijednost 3,40), preferencije tržišta/drugi tip vina (srednja vrijednost 3,24) za najmanje važne prijetnje. Najmanja disperzija odgovora zabilježena je kod pitanja o promjenama u strukturi i teksturi tla uporabom teške mehanizacije (standardna devijacija 0,77) (prilog 12).

Vrijednosti pojedinih grupa SWOT analize dobivene su izračunom srednjih vrijednosti i standardnih devijacija unutar pojedinih grupa.

Rezultati su pokazali da su turizam (prosjeck srednje vrijednosti 4,20) i prirodni resursi (prosjeck srednje vrijednosti 3,85) glavne snage sektora. Najmanje rasipanje odgovora zabilježeno je kod prijenosa znanja (prosjeck standardne devijacije 0,92). Najveća slabost vinarskog sektora je državna administracija (prosjeck srednje vrijednosti 3,96), a najmanje rasipanje odgovora je kod ljudskih resursa (prosjeck standardne devijacije 0,88). Najvažnije prilike sektora su primjena novih tehnologija (prosjeck srednje vrijednosti 2,00) i turizam (prosjeck srednje vrijednosti 2,28). Najniža standardna devijacija je kod pitanja vezanih za program ruralnog razvoja (prosjeck standardne devijacije 0,92). Rezultati su pokazali da tržište (prosjeck srednje vrijednosti 2,62) i državna administracija (prosjeck srednje vrijednosti 2,46) predstavljaju najvažnije prijetnje sektoru. Stručnjaci su pokazali visoku razinu usuglašenosti u svojim odgovorima kod masovnog turizma i onečišćenja okoliša (prosjeck standardne devijacije 0,91) (graf 3, graf 4).



Graf 3: Snage i slabosti vinarija i vinarstva u RH (n = 25)



Graf 4: Prilike i prijetnje vinarija i vinarstva u RH (n = 25)

Analiza pouzdanosti pomoću Cronbach alpha vrijednosti obuhvatila je 61 stavku i dobivena je vrijednost od 0,668, što predstavlja prihvatljivu pouzdanost.

Rezultati analize normalnosti distribucije (indeks zaobljenosti i indeks asimetričnosti) bili su unutar promatranog raspona  $\pm 2,8$ , osim u pojedinačnim slučajevima. Kod okolišnih uvjeta za vinogradarsku proizvodnju, malih usitnjenih površina, porasta turističke potražnje, C.R. vrijednost asimetrije bila je veća od 2,8. Kod pitanja o „problemu radne snage“, C.R. vrijednost zaobljenosti iznosila je -3,78 i C.R. vrijednost za nakošenost iznosila je 6,34. Za varijablu okolišnih uvjeta za vinogradarsku proizvodnju C.R. vrijednost asimetrije je -3,05, za varijablu malih usitnjenih površina -3,20 i za varijablu porast turističke potražnje 2,85 (prilog 13).

Zaključeno je da se daljnja analiza podataka nastavi prema normalnoj distribuciji podataka.

U analizi korelacije izdvojeni su rezultati kod snaga i slabosti vinarskog sektora u RH za koje su vrijednosti veće od 0,329 i koji značajno koreliraju.

Zastarjela tehnologija značajno korelira sa starim vinogradima ( $r = 0,530$ ) i otežanom primjenom tehnologije ( $r = 0,763$ ) na razini od 0,01. Naznačena korelacija može se dovesti u vezu s korelacijom cjenovne nekonkurentnosti koja značajno korelira s neorganiziranošću vinogradara ( $r = 0,608$ ) na razini od 0,01. Turizam značajno korelira s vrhunskim položajima ( $r = 0,620$ ) na razini od 0,01.

Male površine značajno koreliraju s povjerenjem potrošača ( $r = -0,605$ ) na razini od 0,01. Detaljne tablice (prilog 14, prilog 15) nalaze se u prilogu rada.

Nakon toga izdvojeni su rezultati analize korelacije kod prilika i prijetnji vinarskog sektora u RH za vrijednosti veće od 0,329 i koje značajno koreliraju. Razvoj agroturizma i vinskog turizma značajno korelira porastom turističke potražnje ( $r = 0,828$ ) na razini od 0,01. Pad potražnje za vinima značajno korelira s gospodarskom krizom i padom kupovne moći domaćeg stanovništva ( $r = 0,862$ ) na razini od 0,01. Neplaćanje i nelikvidnost značajno korelira s gospodarskom krizom i padom kupovne moći domaćeg stanovništva ( $r = 0,700$ ) na razini 0,01. Detaljne tablice (prilog 16, prilog 17) nalaze se u prilogu rada.

## 5.2. Analiza rizika vinarija u Hrvatskoj

### 5.2.1. Identifikacija rizika i strategija u vinarijama

U provedenoj anketi, odaslanoj na 347 e-mail adrese, povratno je zaprimljen 81 odgovor od čega je 39 bilo potpuno ispunjenih anketa uz izuzetak da je jedan odgovor bio poslan od strane konzultanta. U obradi ankete obuhvaćeno je 38 odgovora ispitanika. S obzirom na prethodna istraživanja, ovo istraživanje nastojalo je ispitanicima ponuditi što veći spektar rizika i strategija za upravljanje rizicima kako bi ih ocijenili.

Prema strukturi ispitanika u anketi je sudjelovalo 84,21% muškaraca. Jednak broj ispitanika bio je u dobi od 31 do 40 godine i 41 do 50 godine života (31,58%). Prema stručnoj spremi 50% ispitanika ima visoku stručnu spremu. S obzirom na to da su svi ispitanici naznačili naziv poslovnog subjekta kako bi se izbjegla obrada dvostrukih anketa, bilo je moguće definirati pravni oblik (d.d., d.o.o., OPG, PZ, obrt, ostalo) i županiju iz koje je poslovni subjekt. Izuzetak je bio jedan poslovni subjekt. Naime, prema više poslovnih subjekata sličnog naziva poslana je anketa, a ispitanik je naznačio skraćeni naziv poslovnog subjekta. Najveći broj ispitanika, 34,21%, ima registrirano poduzeće kao d.o.o. (tablica 15).

Za usporedbu, u istraživanju Heyder i sur. (2010) strategija za suočavanje s nesigurnostima agrobiznisa u Njemačkoj, s obzirom na veličinu farme, uzorak je uključivao vrlo mala poduzeća ali i velika multinacionalna poduzeća, međutim većina odgovora pristigla je od malih i srednjih poduzeća.

Većina ispitanika (23,68%) bila je iz Istarske županije, nakon koje slijedi Zagrebačka (15,79%) i Dubrovačko neretvanska županija (13,16%) (tablica 16).



Tablica 15: Obilježja ispitanika prema dobi, spolu, obrazovanju i vrsti poslovnog subjekta

Obilježje		Frekvencija	Postotak	Kumulativni postotak
Dob	20 do 30	7	18,42	18,42
	31 do 40	12	31,58	50,00
	41 do 50	12	31,58	81,58
	51 do 60	7	18,42	100,00
	Ukupno	38	100,00	
Spol	Ženski	6	15,79	15,79
	Muški	32	84,21	100,00
	Ukupno	38	100,00	
Obrazovanje	SSS	9	23,68	23,68
	VŠŠ	7	18,42	42,11
	VSS	19	50,00	92,11
	Magisterij ili doktorat	3	7,89	100,00
	Ukupno	38	100,00	
Vrsta poslovnog subjekta	d.o.o.	13	34,21	34,21
	OPG	10	26,32	60,53
	d.d.	2	5,26	65,79
	PZ	2	5,26	71,05
	obrt	10	26,32	97,37
	ostalo (znanstvene institucije, ...)	1	2,63	100,00
	Ukupno	38	100,00	

Tablica 16: Struktura ispitanika prema županijama

Županija	Frekvencija	Postotak	Kumulativni postotak
Bjelovarsko-bilogorska	1	2,63	2,63
Dubrovačko-neretvanska	5	13,16	15,79
Istarska	9	23,68	39,47
Međimurska	2	5,26	44,74
nije poznato	1	2,63	47,37
Osječko-baranjska	2	5,26	52,63
Požeško-slavonska	3	7,89	60,53
Splitsko-dalmatinska	3	7,89	68,42
Varaždinska	1	2,63	71,05
Virovitičko-podravska	2	5,26	76,32
Vukovarsko-srijemska	1	2,63	78,95
Zadarska	2	5,26	84,21
Zagrebačka	6	15,79	100,00
Ukupno	38	100	

Na pitanje o radnom mjestu ispitanika ispitanici su mogli davati višestruke odgovore. Od ukupnog broja ispitanika 28,95% ispitanika obavlja više „uloga“ u poslovnom subjektu (tablica 17).


Tablica 17: Radno mjesto ispitanika, neovisno o broju „uloga“ unutar poslovnog subjekta (n = 38)

Radno mjesto		Frekvencija	Postotak	Kumulativni postotak
Član uprave		6	15,80	15,80
Direktor		17	44,70	44,70
Tehnolog		15	39,50	39,50
Ostalo	„vlasnik“, „suvlasnik“	8	21,05	21,05
	„voditelj“, 2poslovođa	2	5,26	26,32
	„i sve ostalo“, „prema potrebi sve“, „radnik menadžer, trgovac“ „i sve ostalo“, „prema potrebi sve“, „radnik menadžer, trgovac“	3	7,89	34,21

Anketa je obuhvatila pitanja o vjerojatnosti pojave i posljedice pojedinih rizika u poslovanju, strategije za upravljanje rizikom, opći dio (strateško upravljanje, strateško upravljanje rizicima, opći podaci).

Kod 68,42% ispitanika tvrtke imaju strateški plan za petogodišnje razdoblje, a 76,32% ispitanika ima definiranu viziju i misiju tvrtke. U istraživanju 52,63% ispitanika nema uz strateški plan provedbeni plan aktivnosti (uključujući kontrolu).

Na pitanje o provedbi aktivnosti, ispitanicima je bilo ponuđena mogućnost višestrukih odgovora, i-istraživanje je pokazalo da 50,00% ispitanika provodi aktivnosti ili projekte *ad hoc*, a ne na temelju jasnog plana (graf 5).




Graf 5: Provođenje aktivnosti/projekata unutar tvrtke prema broju ispitanika (n = 38)

Kada je riječ o normama za sustave, ispitanici su imali mogućnost višestrukog odgovora. Većina ispitanika, 68,42%, nema uvedene norme za sustave, a od uvedenih sustava većina ispitanika (26,32%) ima HACCP sustav.

Nakon pitanja o strateškom planiranju uslijedila su pitanja koja su imala za cilj odrediti percepciju rizika ispitanika i pri tome se tražilo da ocijene vjerojatnost nastanka rizika i posljedicu.

Kada je riječ o rizicima, ispitanici nemaju ustrojstvene jedinice koje se bave rizicima te kod 92,11% ispitanika ne postoji izvještavanje o rizicima. Na pitanje o upravljanju rizicima ispitanici su mogli davati višestruke odgovore. Kod većine ispitanika, 44,74%, direktor je zadužen za upravljanje rizicima (graf 6).



Graf 6: Upravljanje rizicima prema broju ispitanika (n = 38)

Kod analize vjerojatnosti nastanka rizika grupe prirodnih nepogoda 36,84% ispitanika ocijenilo je vjerojatnost nastanka s 31 do 60%, 42,11% ispitanika ocijenilo je vjerojatnost nastanka grupe rizika biologija i okoliš s 31 do 60%, 50,00% ispitanika ocijenilo je vjerojatnost nastanka grupe tržišnih rizika s 11 do 30%, 44,74% ispitanika ocijenilo je vjerojatnost rizika od grupe upravljanja i procesa s vjerojatnošću manjom od 10% i 44,74% ispitanika ocijenilo je vjerojatnost nastanka rizika grupe politike s 31 do 60%.

Kod analize posljedica nastanka rizika 39,47% ispitanika smatra da prirodne nepogode mogu imati značajne posljedice na poslovanje tvrtke, 44,74% ispitanika smatra da biologija i okoliš mogu imati značajne posljedice, 47,37% ispitanika smatra da tržište može imati umjerenu posljedicu na poslovanje tvrtke, 50,00 % ispitanika smatra da upravljanje i procesi imaju umjerenu posljedicu, 52,63% ispitanika smatra da politika i institucije imaju značajne posljedice na poslovanje (tablica 18).

Tablica 18: Vjerojatnosti i posljedica rizika prema grupama rizika

Kategorija		Prirodne nepogode	Biologija i okoliš	Tržište	Upravljanje i procesi	Politika i institucije
Vjerojatnost nastanka rizika	manja od 10%	1	2	2	17	2
	11 do 30%	11	14	19	14	5
	31 do 60%	14	16	13	7	17
	61 do 90%	9	6	4		11
	više od 90%	3				3
	Ukupno	38	38	38	38	38
Posljedica nastanka rizika	zanemariva posljedica		1	3	12	1
	umjerena posljedica	13	13	18	19	6
	značajna	15	17	14	7	20
	kritična	7	7	3		8
	katastrofalna	3				3
	Ukupno	38	38	38	38	38

Prema ocjenama kojima su ispitanici ocjenjivali rizike i grupama izvora rizika srednja vrijednost pokazala je da je najmanja vjerojatnost pojave grupe rizika upravljanje i procesi (11 do 30%). Ostale grupe rizika ocijenjene su s vjerojatnošću 31 do 60%. Značajne posljedice na poslovanje ispitanika imaju grupe rizika prirodnih nepogoda, biologije i okoliša, i politike i institucija. Najmanje je odstupanje u odgovorima kod grupe pitanja o posljedicama rizika upravljanja i procesa (standardna devijacija 0,70).

Unutar pojedinih grupa rizika izdvojeni su rizici s najvećim vjerojatnostima nastanka i najznačajnijim posljedicama. Grupa prirodne nepogode, katastrofe imala je jedan izvor rizika. Kod grupe biologija i okoliš vjerojatnost nastanka rizika pojave bolesti štetnika je od 31 do 60% (srednja vrijednost 3,16) sa značajnim posljedicama (srednja vrijednost 3,05) na poslovanje (tablica 19).

Tablica 19: Grupa rizika biologija i okoliš prema pojedinačnim rizicima (n = 38)

Rizik	Vjerojatnost nastanka rizika		Posljedica nastanka rizika	
	Srednja vrijednost	Standardna devijacija	Srednja vrijednost	Standardna devijacija
Pojava bolesti i štetnika	3,16	1,05	3,05	0,93
Onečišćenje okoliša (ekologija)	1,66	0,81	1,97	0,91

Kod grupe tržište, vjerojatnost pojave rizika pada kupovne moći uzrokovanog gospodarskom krizom, dugog razdoblja naplate, poštivanja ugovornih obveza (kupci i dobavljači), nejasnih i nedovoljno definiranih uvjeta, neplaćanja, pada potražnje vina uzrokovanog gospodarskom krizom, ocijenjena je ocjenom vjerojatnosti 31 do 60% (srednja vrijednost od 3,24 do 3,11), a posljedice koje mogu nastati pojavom takvih rizika mogu biti značajne (srednja vrijednost od 3,16 do 3,00) (tablica 20).

Tablica 20: Grupa rizika tržište prema pojedinačnim rizicima (n = 38)

Rizik	Vjerojatnost nastanka rizika		Posljedica nastanka rizika	
	Srednja vrijednost	Standardna devijacija	Srednja vrijednost	Standardna devijacija
Pad kupovne moći uzrokovan gospodarskom krizom	3,24	1,17	3,16	1,05
Dugo razdoblje naplate, poštivanje ugovornih obveza (kupci i dobavljači), nejasno i nedovoljno definirani uvjeti, neplaćanje	3,13	1,21	3,00	1,21
Pad potražnje za vinom uzrokovan gospodarskom krizom	3,11	1,11	3,05	1,01
Ovisnost o turističkoj potražnji	2,82	1,25	2,87	1,14
Promjenjivost cijene vina (pad cijena <i>outputa</i> )	2,55	0,89	2,61	0,79
Promjenjivost cijene <i>inputa</i> (rast cijena <i>inputa</i> )	2,50	0,92	2,50	0,86
Jačanje konkurencije/jačanje konkurentskih tvrtki	2,34	0,91	2,21	0,84
Jačanje pregovaračke snage potrošača, trgovačkih lanaca, restorana,...	2,16	0,89	2,18	0,77
Razvoj zamjenskih proizvoda (preferencije potrošača mijenjaju se u korist piva, ...)	1,97	0,79	2,05	0,77
Rizik loše reputacije vina	1,95	1,14	2,18	1,16
Promjene preferencija tržišta (...drugi "tip" vina)	1,92	0,85	2,08	0,88
Reputacijski rizik tvrtke	1,89	0,98	2,00	0,99
Jačanje pregovaračke snage dobavljača	1,89	0,73	1,92	0,75
Gubitak identiteta tvrtke kroz globalizacijske procese	1,84	0,97	1,89	0,89

U grupi upravljanje i procesi najznačajniji izvor rizika je cjenovna nekonkurentnost s vjerojatnošću nastanka od 31 do 60% (srednja vrijednost 2,47), koja može imati značajne posljedice (srednja vrijednost 2,37) na poslovanje (tablica 21).

Tablica 21: Grupa rizika upravljanje i procesi prema pojedinačnim rizicima (n = 38)

Rizik	Vjerojatnost nastanka rizika		Posljedica nastanka rizika	
	Srednja vrijednost	Standardna devijacija	Srednja vrijednost	Standardna devijacija
Cjenovna nekonkurentnost	2,47	0,98	2,37	0,85
Nelikvidnost poduzeća	2,32	1,32	2,39	1,37
Ovisnost o kooperantima	2,26	1,20	2,18	1,09
Zalihe vina	2,21	1,04	2,24	0,91
Pogreške zaposlenika, bolovanja, smrt...	2,16	1,24	2,05	1,18
Izostanak navodnjavanja u kritičnom razdoblju (suša)	2,13	1,26	2,05	1,14
Niska educiranost zaposlenika:, manjak/višk zaposlenika	2,13	1,07	2,16	1,03
Stari vinogradi u „lošoj kondiciji“	2,08	1,17	2,13	1,07
Nedovoljna kontrola kvalitete (propusti u kontroli kvalitete)	2,03	1,03	2,21	1,09
Rizik menadžerske pogreške	1,95	0,87	1,97	0,82
Promjena poslovne politike na orijentiranost na prinos	1,89	0,80	2,08	0,85
Promjene u tehnologiji proizvodnje (zastarjela tehnologija, nedovoljno uvođenje nove tehnologije)	1,87	0,84	2,16	0,89
IT nesigurnost (Cybersecurity rizik)	1,61	0,68	1,68	0,81
Značajne promjene u strukturi tla uzrokovane upotrebom teške mehanizacije (pr. zbijanje tla, ...)	1,37	0,67	1,66	0,78
Industrijska špijunaža	1,34	0,53	1,39	0,64

Kod grupe rizika politika i institucije rizik složene administracije ispitanici su ocijenili s vjerojatnošću nastanka 61 do 90% (srednja vrijednost 3,53), i značajnom posljedicom (srednja vrijednost 3,29) na poslovanje (tablica 22).

Tablica 22: Grupa rizika politika i institucije prema pojedinačnim rizicima (n = 38)

Rizik	Vjerojatnost nastanka rizika		Posljedica nastanka rizika	
	Srednja vrijednost	Standardna devijacija	Srednja vrijednost	Standardna devijacija
Skupa i složena državna administracija	3,53	1,13	3,29	1,09
Nedovoljne potpore za otežane uvjete gospodarenja	3,13	1,23	3,05	1,14
Nesigurnosti regulatornih i zakonskih politika	3,05	1,11	3,03	1,03
Nedovoljan nadzor tržišta, crno tržište,...	3,03	1,17	3,08	1,15
Društveno politička situacija (gospodarske sankcije, ...)	2,84	1,24	2,84	1,13
Visoka cijena kapitala (visoke kamatne stope)	2,76	1,34	2,92	1,32
Promjenjivost kamatnih stopa	2,58	1,31	2,68	1,21
Promjene poljoprivredne i trgovinskih politika (EU, CEFTA,...)	2,32	0,96	2,55	1,13

Bodovna ljestvica rizika (*risk scorecard*) prikazana je prema Jaffee i sur. (2010). Rezultat izračuna rizika umnožak je srednje vrijednosti vjerojatnosti nastanka rizika i srednje vrijednosti posljedica rizika.

Za grupe rizika prirodnih nepogoda i politike i institucija rezultat izračuna rizika imao je najveću vrijednost, 9, i time te grupe rizika pripadaju skupini prioriteta srednje očekivanih gubitaka. Grupa rizika biologija i okoliš, upravljanje i procesi te tržište u grupi su niskog očekivanog gubitka (tablica 23).

Tablica 23: Rangiranje očekivanih gubitka prema grupama rizika (n = 38)

Rizik		Posljedica				
		zanemariva	umjerena	značajna	kritična	katastrofalna
Vjerojatnost	više od 90%					
	61 do 90%					
	31 do 60%			Prirodne nepogode Politika i institucije		
	11 do 30%		Biologija i okoliš Upravljanje i procesi Tržište			
	manja od 10%					

Prioritet 1 (tamno siva boja) = očekuju se visoki gubici, Prioritet 2 (svijetlo siva boja) = očekuju se srednji gubici, Prioritet 3 (bijela boja) = očekuju se niski gubici

Prema pojedinačnim rizicima u grupama najveću srednju vrijednost rizika (12) dobila je skupa i složena državna administracija (tablica 24) i time ulazi u prioritete visoko očekivanih gubitaka (tablica 25).

Tablica 24: Rangiranje očekivanih gubitka prema pojedinačnim rizicima (n = 38)

Grupa rizika	Rizik	Srednja vrijednost Vjerojatnost	Srednja vrijednost Posljedica	Rezultat (vjerojatnost x posljedica)
Prirodne nepogode	Klimatske promjene (prirodne nepogode,...)	3,05	3,00	9,16
Biologija i okoliš	Onečišćenje okoliša (ekologija)	1,66	1,97	3,27
	Pojava bolesti i štetnika	3,16	3,05	9,64
Upravljanje i procesi	Izostanak navodnjavanja u kritičnom razdoblju (suša)	2,13	2,05	4,38
	Rizik menadžerske pogreške	1,95	1,97	3,84
	Značajne promjene u strukturi tla uzrokovane upotrebom teške mehanizacije (pr. zbijanje tla, ...)	1,37	1,66	2,27
	Stari vinogradi u „lošoj kondiciji“	2,08	2,13	4,43
	Promjene u tehnologiji proizvodnje (zastarjela tehnologija, nedovoljno uvođenje nove tehnologije)	1,87	2,16	4,03
	Nedovoljna kontrola kvalitete (propusti u kontroli kvalitete)	2,03	2,21	4,48



	Promjena poslovne politike na orijentiranost na prinos	1,89	2,08	3,94
	Ovisnost o kooperantima	2,26	2,18	4,94
	Nelikvidnost poduzeća	2,32	2,39	5,55
	Zalihe vina	2,21	2,24	4,94
	Niska educiranost zaposlenika:, manjak/višak zaposlenika	2,13	2,16	4,60
	Pogreške zaposlenika, bolovanja, smrt...	2,16	2,05	4,43
	Cjenovna ne konkurentnost	2,47	2,37	5,86
	IT nesigurnost ( <i>Cybersecurity</i> rizik)	1,61	1,68	2,70
	Industrijska špijunaža	1,34	1,39	1,87
Tržište	Rizik loše reputacije vina	1,95	2,18	4,25
	Reputacijski rizik tvrtke	1,89	2,00	3,79
	Gubitak identiteta tvrtke kroz globalizacijske procese	1,84	1,89	3,49
	Dugo razdoblje naplate, poštivanje ugovornih obveza (kupci i dobavljači), nejasno i nedovoljno definirani uvjeti, neplaćanje	3,13	3,00	9,39
	Promjenjivost cijene <i>inputa</i> (rast cijena <i>inputa</i> )	2,50	2,50	6,25
	Promjenjivost cijene vina (pad cijena <i>outputa</i> )	2,55	2,61	6,65
	Jačanje konkurencije/jačanje konkurentskih tvrtki	2,34	2,21	5,18
	Jačanje pregovaračke snage dobavljača	1,89	1,92	3,64
	Jačanje pregovaračke snage potrošača, trgovačkih lanaca, restorana,...	2,16	2,18	4,71
	Razvoj zamjenskih proizvoda (preferencije potrošača mijenjaju se u korist piva, ...)	1,97	2,05	4,05
	Promjene preferencija tržišta (...drugi "tip," vina)	1,92	2,08	3,99
	Ovisnost o turističkoj potražnji	2,82	2,87	8,08
	Pad potražnje za vinom uzrokovan gospodarskom krizom	3,11	3,05	9,48
	Pad kupovne moći uzrokovan gospodarskom krizom	3,24	3,16	10,22
Politika i institucije	Visoka cijena kapitala (visoke kamatne stope)	2,76	2,92	8,07
	Promjenjivost kamatnih stopa	2,58	2,68	6,92
	Promjene poljoprivredne i trgovinskih politika (EU, CEFTA,...)	2,32	2,55	5,91
	Nesigurnosti regulatornih i zakonskih politika	3,05	3,03	9,24

Društveno-politička situacija (gospodarske sankcije, ...)	2,84	2,84	8,08
Nedovoljan nadzor tržišta, crno tržište,...	3,03	3,08	9,32
Skupa i složena državna administracija	3,53	3,29	11,60
Nedovoljne potpore za otežane uvjete gospodarenja	3,13	3,05	9,56

Rezultat rizika umnožak je vjerojatnosti i posljedice rizika. Vjerojatnost: 1 pretpostavlja vjerojatnost pojave rizika manju od 10%, ocjena 2 pretpostavlja vjerojatnost 11-30%, ocjena 3 vjerojatnost 31-60%, ocjena 4 vjerojatnost 61-90% dok ocjena 5 pretpostavlja vjerojatnost pojave rizika s vjerojatnošću od 90% i više postotaka. Posljedica: Ocjena 1 pretpostavljala je zanemarivu posljedicu rizika, ocjena 2 umjerenu, ocjena 3 značajnu, ocjena 4 kritičnu i ocjena 5 pretpostavljala je katastrofalnu posljedicu nastanka rizika.

Tablica 25: Rangiranje očekivanih gubitka prema rizicima (n = 38)

Rizik		Posljedica			
		zanemariva	umjerena	značajna	kritična
Vjerojatnost	više od 90%				
	61-90%			skupa i složena državna administracija	
	31-60%			pad kupovne moći uzrokovan gospodarskom krizom, nedovoljan nadzor tržišta, pojava bolesti štetnika, crno tržište,..., pad potražnje za vinom uzrokovan gospodarskom krizom, nedovoljne potpore za otežane uvjete gospodarenja, nesigurnosti regulatornih i zakonskih politika, klimatske promjene, dugo razdoblje naplate, poštivanje ugovornih obveza (kupci i dobavljači), nejasno i nedovoljno definirani uvjeti, neplaćanje, visoka cijena kapitala (visoke kamatne stope), ovisnost o turističkoj potražnji, društveno politička situacija (gospodarske sankcije, ...), promjenjivost kamatnih stopa, promjenjivost cijene vina (pad cijena <i>outputa</i> ), promjenjivost cijene <i>inputa</i> (rast cijena <i>inputa</i> )	
	11-30%		nelikvidnost poduzeća, cjenovna nekonkurentnost, zalihe vina, nedovoljna kontrola kvalitete (propusti u kontroli kvalitete), jačanje konkurencije/jačanje konkurentskih tvrtki, ovisnost o kooperantima, rizik loše reputacije vina, jačanje pregovaračke snage potrošača, trgovačkih lanaca, restorana,..., promjene u tehnologiji proizvodnje (zastarjela tehnologija, nedovoljno uvođenje nove tehnologije), niska educiranost zaposlenika, manjak/višak zaposlenika, stari vinogradi u „lošoj kondiciji“, promjena poslovne politike na orijentiranost na prinos, promjene preferencija tržišta (...drugi „tip“ vina), izostanak navodnjavanja u kritičnom razdoblju (suša), pogreške zaposlenika, bolovanja, smrt..., razvoj zamjenskih proizvoda (preferencije potrošača se mijenjaju u korist piva, ...), reputacijski rizik tvrtke, onečišćenje okoliša (ekologija), rizik menadžerske pogreške, jačanje pregovaračke snage dobavljača, gubitak identiteta tvrtke kroz globalizacijske procese, IT nesigurnost ( <i>Cybersecurity</i> rizik)	promjene poljoprivredne i trgovinskih politika (EU, CEFTA,...)	
	manja od 10%	industrijska špijunaža	značajne promjene u strukturi tla uzrokovane upotrebom teške mehanizacije (pr. zbijanje tla, ...)		

U sljedećih pet godina za najveće prepreke u poslovanju ispitanici su izdvojili prirodne nepogode (73,68%) i tržište (71,05%) (tablica 26). Ispitanicima je dana mogućnost višestrukog odgovora između šest grupa izvora rizika: prirodne nepogode/katastrofe (uključujući ekstremne vremenske prilike), biologija i okoliš (štetnici i bolesti; zagađenost uvjetovana lošim sanitarnim uvjetima, ljudima ili bolestima; kontaminacije koje utječu na sigurnost hrane, prirodne resurse/okoliš, odnosno proizvodnju i preradu), tržište, logistika i infrastruktura, upravljanje i procesi, politika i institucije.

Tablica 26: Očekivanja ispitanika o utjecaju grupa rizika na poslovanje, u petogodišnjem razdoblju (n = 38)

Grupa rizika	Frekvencija	Postotak	Kumulativni postotak
Prirodne nepogode /katastrofe	28	73,68	73,68
Tržište	27	71,05	71,05
Politika i institucije	24	63,16	63,16
Biologija i okoliš	13	34,21	34,21
Logistika i infrastruktura	5	13,16	13,16
Upravljanje i procesi	4	10,53	10,53

Kod pitanja o važnosti primjene strategija za upravljanje rizicima u poslovanju 50% ispitanika smatra strategije izvan gospodarstva važnima za upravljanje rizicima u poslovanju, 84,21% ispitanika smatra strategije na gospodarstvu važnima, i 52,63% ispitanika smatra strategije prijenosa rizika važnima u upravljanju rizicima u poslovanju, poduzetništvu. Ispitanici ponekad (34,21%) i često (34,21%) primjenjuju strategije izvan gospodarstva. Kod 57,89% ispitanika ponekad su u primjeni strategije na gospodarstvu, a 44,74% ispitanika rijetko primjenjuje strategije prijenosa rizika (tablica 27).

Tablica 27: Važnost i učestalost primjene strategija za upravljanje rizicima u poslovanju prema grupama rizika i broju ispitanika

Kategorija	Izvan gospodarstva	Na gospodarstvu	Prijenos rizika
Važnost primjene strategija	uopće nije važna		
	nije važna	1	3
	bez utjecaja	2	13
	važna	32	20
	jako važna	3	2
	Ukupno	38	38
Učestalost primjene strategija	nikada		4
	rijetko	5	17
	ponekad	22	10
	često	10	7
	uvijek	1	
	Ukupno	38	38

U grupi strategija izvan gospodarstva ispitanici ocjenjuju proizvodnu diversifikaciju tvrtke i korištenje programa potpore (nacionalni i EU programi), važnim strategijama (srednja vrijednost 4,47), no kada je riječ o primjeni strategije, ispitanici naznačene strategije ponekad koriste (srednja vrijednost 3,08) (tablica 28).

Tablica 28: Strategije za upravljanje rizicima izvan gospodarstva (n = 38)

Strategija	Važnost primjene strategije		Učestalost primjene strategije	
	Srednja vrijednost	Standardna devijacija	Srednja vrijednost	Standardna devijacija
Korištenje programa potpore (nacionalni i EU programi)	4,47	0,56	3,08	1,22
Proizvodna diversifikacija tvrtke	3,61	0,68	2,87	1,02

Ispitanici strategiju pridržavanja tehnologije i agrotehničkih rokova smatraju najvažnijom (srednja vrijednost 4,42) i uvijek je primjenjuju (srednja vrijednost 4,53).

Ispitanici često primjenjuju strategije korištenja vlastitog zemljišta, prodaje proizvoda putem više različitih kanala, stalnog učenja i informiranosti i osiguranja dovoljnog broja radnika u „vrhovima“ proizvodnje. Rijetko se primjenjuju strategije lizinga, najma opreme i mehanizacije, navodnjavanja, protumraznog, protugradnog sustava, zaliha rezervnih dijelova i prodaje imovine (tablica 29).

Tablica 29: Strategije za upravljanje rizicima na gospodarstvu (n = 38)

Strategija	Važnost primjene strategije		Učestalost primjene strategije	
	Srednja vrijednost	Standardna devijacija	Srednja vrijednost	Standardna devijacija
Pridržavanje tehnologije i agrotehničkih rokova	4,42	0,50	4,53	0,60
Prodaja proizvoda putem više različitih kanala	4,39	0,55	3,92	0,85
Ljudski potencijali (dovoljan broj radnika u „vrhovima“ proizvodnje)	4,29	0,61	3,68	0,87
Stalno učenje i informiranost (tečajevi, treninzi)	4,26	0,64	3,74	0,95
Organizirana nabava <i>inputa</i>	4,13	0,62	3,32	1,07
Zalihe gotovine i ostale rezerve u slučaju financijskih rizika	4,13	0,62	3,03	1,22
Privremeno zapošljavanje	4,03	0,94	3,39	1,03
Korištenje vlastitog zemljišta	4,00	0,96	4,21	1,21
Sustav nabave i logistike (repromaterijal, ...)	3,95	0,77	3,45	1,08
Zalihe vina	3,92	0,71	3,37	1,02

Korištenje stručnih-konzultantskih usluga	3,55	0,95	3,08	1,00
Zemljopisna i vremenska diversifikacija proizvoda	3,47	0,80	2,79	1,09
Navodnjavanje	3,47	1,06	1,87	1,14
Protumrazni i protugradni sustav	3,42	1,08	1,66	1,21
Lizing i/ili najam opreme i mehanizacije	3,32	0,96	2,08	0,97
Zalihe rezervnih dijelova	3,24	0,85	2,79	1,02
Prodaja imovine	2,82	1,01	1,61	0,86

Ispitanicima su važne strategije konkurentskog udruživanja, prodajnih ugovora i ugovora s kooperantima te proizvodnje za poznatog kupca. No, kada je riječ o učestalosti primjene strategije osiguranja, prodajnih ugovora, ugovora s kooperantima, proizvodnje za poznatog kupca (robne marke, ...), ispitanici ih ponekad koriste. Rijetko se primjenjuju strategije konkurentskog udruživanja (klasteri, vertikalno i horizontalno), *hedginga* i faktoringa (tablica 30).

Tablica 30: Strategije za upravljanje rizicima prijenosom rizika (n = 38)

Strategija	Važnost primjene strategije		Učestalost primjene strategije	
	Srednja vrijednost	Standardna devijacija	Srednja vrijednost	Standardna devijacija
Konkurentsko udruživanje (klasteri, vertikalno i horizontalno)	3,89	0,89	2,29	1,29
Prodajni ugovori, ugovori s kooperantima	3,74	0,79	2,92	1,15
Proizvodnja za poznatog kupca (robne marke,...)	3,55	0,55	2,55	1,06
Osiguranje (opreme, objekata...)	3,42	0,92	3,26	1,27
<i>Hedging</i>	3,18	0,98	2,11	1,16
Faktoring	3,11	1,01	2,05	1,14

Ispitanici sve grupe strategija smatraju važnima u poslovanju (srednja vrijednost od 3,55 do 4,34), ali ponekad primjenjuju naznačene strategije (srednja vrijednost od 2,53 do 3,26).

Na pitanje o razlozima zašto se učestalije ne koriste navedene strategije za upravljanje rizikom, posebno za ocjene: 1 - nikada, 2 - rijetko i 3 - ponekad, ispitanici su mogli odabrati više odgovora. Najčešći su razlog nedovoljna financijska sredstva (76,32%) (tablica 31).

Tablica 31: Razlozi zbog kojih ispitanici učestalije ne koriste strategije upravljanja rizicima u poslovanju (n = 38)

Razlozi	Frekvencija	Postotak	Kumulativni postotak
Nedovoljna financijska sredstva	29	76,32	76,32
Manjak vremena	19	50,00	50,00
Preopterećenost postojećih ljudskih resursa	13	34,21	34,21
Nemogućnost zapošljavanja eksperata	7	18,42	18,42
Na tržištu rada nema dovoljno eksperata	6	15,79	15,79
Nedostatak znanja za primjenu strategija	5	13,16	13,16
Ostalo (nije potrebno za način poslovanja, za neke nema potrebe)	2	5,26	

Analiza pouzdanosti pomoću Cronbach alpha vrijednosti obuhvatila je 130 stavaka, koje su uključivale pitanja vezana za ocjenu vjerojatnosti pojave rizika, posljedica, važnosti primjene strategija i učestalosti primjene strategija i dobivena je vrijednost od 0,943. Vrijednost Cronbach alpha za grupirane izvore rizika i strategije iznosi 0,797 i implicirana vrijednost je vrlo dobra (tablica 32).

Tablica 32: Pouzdanost rezultata provedenog istraživanja

Cronbach's Alpha vrijednost	Broj stavaka
0,943	130
0,797	16

Nakon provjere pouzdanosti pristupljeno je provjeri normalnosti korištenjem zavisne i nezavisne varijable.

Za zavisne varijable naznačene su vjerojatnosti i posljedice rizika, važnost primjene strategija i učestalost primjene strategija, razlozi zašto se učestalije ne koriste pojedine strategije, dok su nezavisne varijable obilježja ispitanika (dob, spol, obrazovanje, vrsta organizacije, radno mjesto ispitanika). U analizi rezultata indeksa zaobljenosti i indeksa asimetričnosti razmatrane su vrijednosti u rasponu  $\pm 2,8$ . Rezultati su većinom pokazali normalnu distribuciju za obilježje ispitanika (dob, spol, obrazovanje, pravni status poslovnog

subjekta ispitanika, radno mjesto ispitanika) i grupe rizika vjerojatnosti nastanka rizika i posljedice rizika, grupe strategija važnosti primjena strategija i učestalosti primjene strategija. Iako su u većini rezultata vrijednosti bile u rasponu od -2,8 do +2,8, a za vrijednosti z-score koje su bile veće ili manje od  $\pm 2,8$  primjenjivani su testovi za normalnu distribuciju.

U analizi korelacije promatrane su korelacije pojedinih grupa rizika prema vjerojatnosti nastanka i posljedicama rizika i pojedinih grupa strategija prema važnosti i učestalosti primjene strategija u vlastitom poslovanju.

Izdvojeni su rezultati analize korelacije grupa rizika vjerojatnosti nastanka rizika i posljedica rizika za vrijednosti koje su veće od 0,329 i značajno koreliraju.

Vjerojatnost nastanka rizika biologije i okoliša značajno korelira s vjerojatnošću nastanka grupe rizika prirodnih nepogoda ( $r = 0,666$ ) na razini od 0,01. Vjerojatnost nastanka rizika grupe rizika upravljanja i procesa značajno korelira s vjerojatnošću nastanka rizika grupe rizika biologije i okoliša ( $r = 0,433$ ) i tržište ( $r = 0,513$ ) na razini od 0,01. Vjerojatnost nastanka rizika grupe rizika politike i institucija značajno korelira s vjerojatnošću nastanka rizika grupe rizika tržišta ( $r = 0,515$ ) na razini 0,01.

Posljedice grupe rizika prirodnih nepogoda značajno koreliraju s vjerojatnošću nastanka rizika grupe rizika prirodnih nepogoda ( $r = 0,649$ ) i grupom rizika biologija i okoliš ( $r = 0,539$ ) na razini od 0,01. Posljedice grupe rizika biologije i okoliša značajno koreliraju s vjerojatnošću nastanka rizika grupe rizika biologije i okoliša ( $r = 0,494$ ) i posljedicama prirodnih nepogoda ( $r = 0,561$ ) na razini 0,01. Posljedice grupe rizika tržišta značajno koreliraju s vjerojatnošću nastanka rizika grupe rizika tržišta ( $r = 0,769$ ) i politike i institucija ( $r = 0,422$ ) na razini 0,01, i srednje koreliraju s vjerojatnošću nastanka rizika grupe rizika upravljanja i procesa ( $r = 0,350$ ) i posljedicama rizika grupe rizika biologije i okoliša ( $r = 0,393$ ) na razini 0,05. Posljedice grupe rizika upravljanja i procesa značajno koreliraju s vjerojatnošću nastanka grupe rizika tržišta ( $r = 0,428$ ), vjerojatnošću nastanka grupe rizika upravljanja i procesa ( $r = 0,641$ ) i posljedicama nastanka rizika grupe rizika biologije i okoliša ( $r = 0,541$ ) na razini 0,01 i srednje koreliraju s vjerojatnošću nastanka grupe rizika biologije i okoliša ( $r = 0,400$ ) i s posljedicama grupe rizika prirodnih nepogoda ( $r = 0,371$ ) na razini 0,05. Posljedice rizika grupe rizika politike i institucija, značajno koreliraju s vjerojatnošću pojave grupe rizika politike i institucija ( $r = 0,783$ ) i posljedicama rizika grupe rizika tržišta ( $r = 0,454$ ) na razini 0,01 (tablica 33).



Tablica 33: Korelacija grupa rizika vjerojatnosti nastanka rizika i posljedica rizika (n = 38)

Varijabla	Prirodne nepogode (vjeroj.)	Biologija i okoliš (vjeroj.)	Tržište (vjeroj.)	Upravljanje i procesi (vjeroj.)	Politika i institucije (vjeroj.)	Prirodne nepogode (poslj.)	Biologija i okoliš (poslj.)	Tržište (poslj.)	Upravljanje i procesi (poslj.)	Politika i institucije (poslj.)
Prirodne nepogode (vjeroj.)	1									
Biologija i okoliš (vjeroj.)	,666**	1								
Tržište (vjeroj.)	,288	,351*	1							
Upravljanje i procesi (vjeroj.)	,308	,433**	,513**	1						
Politika i institucije (vjeroj.)	,244	,088	,515**	,152	1					
Prirodne nepogode (poslj.)	,649**	,539**	,152	,268	,091	1				
Biologija i okoliš (poslj.)	,192	,494**	,320	,316	,133	,561**	1			
Tržište (poslj.)	,148	,236	,769**	,350*	,422**	,191	,393*	1		
Upravljanje i procesi (poslj.)	,244	,400*	,428**	,641**	,042	,371*	,541**	,567**	1	
Politika i institucije (poslj.)	,021	-,079	,280	,023	,783**	,066	,128	,454**	,164	1
**. Korelacija je značajna na razini 0.01 (2-tailed).										
*. Korelacija je značajna na razini 0.05 (2-tailed).										

Izdvojeni su rezultati analize korelacije grupa rizika vjerojatnosti i posljedica nastanka rizika za vrijednosti koje su veće od 0,329 i značajno koreliraju.

Važnost primjene strategija grupe strategije prijenosa rizika značajno korelira s važnošću primjene strategija na gospodarstvu ( $r = 0,421$ ) na razini 0,01, i srednje korelira sa strategijama izvan gospodarstva ( $r = 0,346$ ) na razini 0,05.

Učestalost primjene strategija izvan gospodarstva značajno korelira s važnošću primjene strategija izvan gospodarstva ( $r = 0,495$ ) na razini 0,01, i srednje korelira s važnošću primjene strategija prijenosa rizika ( $r = 0,384$ ) na razini 0,05. Učestalost primjene strategija na gospodarstvu srednje korelira i s važnošću primjene strategija izvan gospodarstva ( $r = 0,411$ ), strategija na gospodarstvu ( $r = 0,411$ ) i strategija prijenosa rizika ( $r = 0,331$ ) na razini 0,05. Učestalost primjene strategija prijenosa rizika značajno korelira s važnošću primjene strategija prijenosa rizika ( $r = 0,443$ ) i učestalošću primjene strategija na gospodarstvu ( $r = 0,437$ ) na razini 0,01 i srednje korelira s učestalošću primjene strategija izvan gospodarstva ( $r = 0,374$ ) na razini 0,05 (tablica 34).

Tablica 34: Korelacija grupa strategija važnosti primjene strategija i učestalosti primjene strategija ( $n = 38$ )


Varijabla	Izvan gospodarstva (važnost)	Na gospodarstvu (važnost)	Prijenos rizika (važnost)	Izvan gospodarstva (učestalost)	Na gospodarstvu (učestalost)	Prijenos rizika (učestalost)
Izvan gospodarstva (važnost)	1					
Na gospodarstvu (važnost)	,380*	1				
Prijenos rizika (važnost)	,346*	,421**	1			
Izvan gospodarstva (učestalost)	,495**	,254	,384*	1		
Na gospodarstvu (učestalost)	,411*	,411*	,331*	,643**	1	
Prijenos rizika (učestalost)	,241	,210	,443**	,374*	,437**	1
*. Korelacija je značajna na razini 0.05 (2-tailed).						
**. Korelacija je značajna na razini 0.01 (2-tailed).						

### 5.2.2. Rizici u vinarstvu

U analizi rizika i njihovom utjecaju na poslovanje analizirani su proizvodni, tržišni i institucionalni rizici temeljem dostupnih podataka.

Analiza distribucije razdiobe proizvodnog rizika obuhvatila je promjenu proizvodnje i prinosa u razdoblju od 2005. do 2015.

Tijekom promatranog razdoblja, prinosi grožđa kreću se od najnižih 5,20 t/ha u 2014. godini, 5,50 t/ha u 2008. godini do 6,90 t/ha u 2013. kada je zabilježen najviši prinos. U 2015. godini zabilježen je prinos od 6,00 t/ha. U razdoblju od 2005. do 2013. ukupna proizvodnja vina u Republici Hrvatskoj veća je od 1.200.000 hl. U odnosu na 2013. godinu, u 2014. zabilježeno je smanjenje proizvodnje od 32,59%, dok je u 2015. godini zabilježeno smanjenje od 20,58% (Državni zavod za statistiku Republike Hrvatske, 2005. - 2015., slika 8).






Slika 8: Promjena prinosa i količina proizvodnje u razdoblju od 2005. do 2015. godine


Izvor: Državni zavod za statistiku Republike Hrvatske, 2005. - 2015., obrada autora

Državni zavod za statistiku prikuplja podatke o potrošnji po energentima, nabavi i utrošenim sirovinama i materijalima za proizvodnju proizvoda i o industrijskoj proizvodnji za vlastiti račun i na osnovi ugovora za mirna, specijalna, pjenušava vina i mošt (prilog 3).

U analizi potrošnje i utroška sirovina i materijala, trošak *inputa* prosječna je cijena utroška sirovine po jedinici mjere (Državni zavod za statistiku Republike Hrvatske, 2017). Analizirani su: grožđe za vino (tona), mošt od grožđa (hl), i u proizvodnji pića električna energija (MWh), para i vrela voda (GJ), benzin iz fosilnih sirovina (tona), dizelska goriva iz fosilnih sirovina (tona), ekstra lako i specijalno loživo ulje (tona), nisko sumporno loživo ulje (tona), visoko sumporno loživo ulje (tona), prirodni plin, distribuiran mrežom (tis. m<sup>3</sup>), ukapljeni plin (tona)

u razdoblju od 2005. do 2015. Tijekom promatranog razdoblja, uspoređujući 2015. i 2005. godinu, prosječne cijene utroška sirovine po jedinici mjere svih energenata u proizvodnji pića rasle su prosječno 27,31%. Od energenata značajan je rast prosječne cijene pare i vrele vode (100,00%), prirodnog plina (57,37%) i ekstra lakog i specijalnog loživog ulja od 24,54%. Prosječne cijene grožđa pale su za 3,84% dok su cijene mošta od grožđa rasle za 34,76%. Podaci o prosječnim proizvođačkim cijenama vina odnose se samo na vino dobiveno od grožđa iz vlastite proizvodnje, a o prodanim količinama podaci se odnose na zbroj za vlastiti račun i na osnovi ugovora za mirna, specijalna, pjenušava vina i mošt. Prosječne proizvođačke cijene grožđa pale su za 23,85%, dok su proizvođačke cijene stolnog vina rasle za 25,96%. S druge strane došlo je i do pada ukupne količine prodanog vina (mirna, pjenušava i specijalna vina, i mošt) za 18,63% i pada ukupne vrijednosti od 6,98% te rasta jedinične cijene prodanog vina od 14,32% (slika 9).





Slika 9: Prosječna cijena potrošnje u propisanoj mjernoj jedinici energenta u proizvodnji pića za razdoblje od 2005. do 2015. godine

Izvor: Državni zavod za statistiku Republike Hrvatske, 2005. - 2015., (2015, 2017, a, b, c) obrada autora

U korelaciji su promatrane prosječne proizvođačke cijene za vino i grožđe, jedinične cijene i prosječne cijene utroška po jedinici mjere sirovina, materijala i energenata. Izračun jedinične cijene je količnik vrijednosti prodanih proizvoda i ukupnih količina prodanih proizvoda temeljem Prodcom istraživanja Državnog zavoda za statistiku Republike Hrvatske. Od energenata izdvojeni su oni koji su imali najznačajniji rast prosječne cijene utroška sirovine po jedinici mjere. Promatrani su rezultati analize korelacije za vrijednosti koje su veće od 0,329 i značajno koreliraju na razini 0,05 i 0,01.

Prosječne proizvođačke cijene za stolno vino koreliraju na razini od 0,05 s jediničnom cijenom ( $r = 0,619$ ), utroškom energenata pare i vrele vode ( $r = 0,418$ ) te prirodnim plinom ( $r = 0,524$ ).

Prosječne proizvođačke cijene grožđa koreliraju na razini od 0,05 s utroškom grožđa ( $r = 0,692$ ) i na razini od 0,01 s energentima parom i vrelom vodom ( $r = -0,812$ ) te prirodnim plinom ( $r = -0,838$ ). Jedinična cijena korelira s utroškom vina ( $r = 0,542$ ). Utrošak grožđa korelira na razini 0,05 s utroškom plina ( $r = -0,664$ ). Utrošak mošta od grožđa korelira s utroškom energenata prirodnim plinom ( $r = 0,379$ ) i ekstra lakim i specijalnim loživim uljem ( $r = 0,434$ ).

Za institucionalni rizik promatrana je promjena poljoprivredne politike, standarda kvalitete, uvozno-izvozne politike.

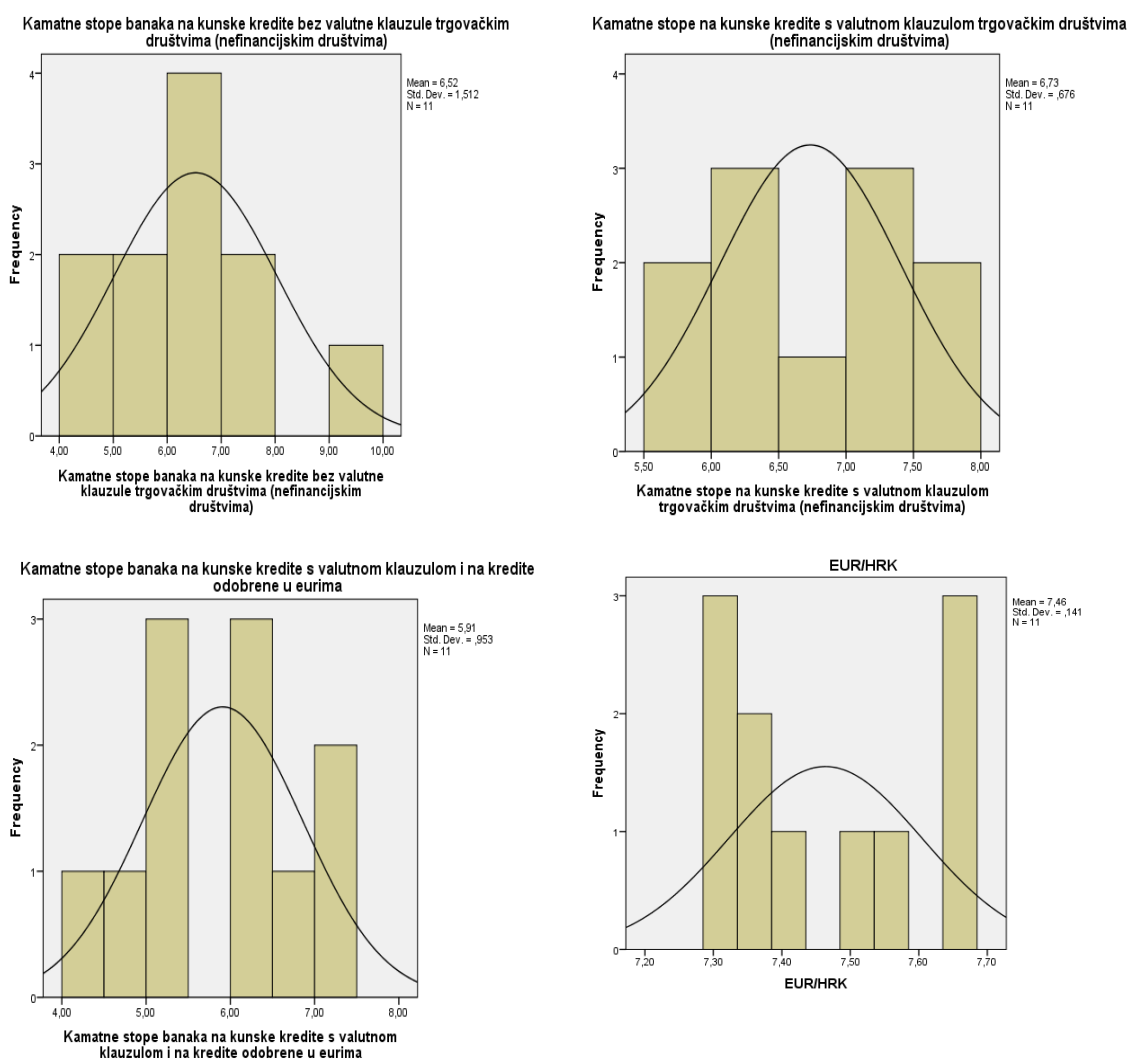
Proizvodnja i promet vina u Republici Hrvatskoj regulirani su Zakonom o vinu i pratećim pravilnicima. Pristupanje Republike Hrvatske u području poljoprivrede, vinogradarstva i vinarstva značilo je i prilagodbu nacionalne legislative s pravnom stečevinom Europske unije. Osim Zakona o vinu i njegovih pratećih pravilnika na snazi su još i sljedeći zakoni i uredbe koji su u užem ili širem smislu povezani sa stavljanjem vina u promet: Zakon o zajedničkoj organizaciji tržišta poljoprivrednih proizvoda i posebnim mjerama i pravilima vezanim za tržište poljoprivrednih proizvoda, Zakon o uređenju tržišta poljoprivrednih proizvoda, Zakon o oznakama zemljopisnog podrijetla i oznakama izvornosti proizvoda i usluga, Zakon o poljoprivredi, Zakon o hrani, Zakon o normizaciji, Zakon o službenim kontrolama koje se provode sukladno propisima o hrani, hrani za životinje, o zdravlju i dobrobiti životinja, Zakon o općem upravnom postupku. Od uredbi značajne su Uredba Komisije (EU) br. 436/2009, Uredba Komisije (EU) br. 555/2008, Uredba Komisije (EU) br. 606/2009, Uredba Komisije (EU) br. 607/2009, Uredba Komisije (EU) br. 1308/2013, Uredba Komisije (EU) br. 251/2014, naputak o provedbi članka 73. stavka 4. Uredbe Komisije (EZ) br. 607/2009 od 14. srpnja 2009. i naputak o provedbi uredbe Europskog parlamenta i Vijeća (EU) br. 1308/2013 od 17. prosinca 2013. (Hrvatski centar za poljoprivredu, hranu i selo, 2017, c). U prometu vina Republike Hrvatske prema kategorijama kakvoće u razdoblju od 2011. do 2015. godine dolazi do smanjenja prometa stolnog vina, s udjelom od 30,48% u ukupnom prometu vina 2011. godine, do 24,65% u 2015. godini. U istom razdoblju dolazi i do povećanja udjela kvalitetnog (67,91% u 2015.) i vrhunskog vina (6,47% u 2015.) u ukupnom prometu vina domaće proizvodnje (tablica 35).

Tablica 35: Udio kategorija kakvoće vina u prometu vina Republike Hrvatske (%)

Opis	Domaća proizvodnja				
	2011.	2012.	2013.	2014.	2015.
Stolno (vino bez ZOI-a, sa ZOI-em, s KZP-om)	30,48	35,53	29,54	26,24	24,65
Kvalitetno	63,58	58,93	64,94	67,99	67,91
Vrhunsko	5,09	4,85	4,60	5,11	6,47
Pjenušavo, biser, gazirano	0,69	0,45	0,44	0,52	0,87
Specijalno (desertno, aromatizirano, likersko)	0,15	0,24	0,48	0,15	0,10
Ukupno	100,00	100,00	100,00	100,00	100,00

Izvor: Hrvatski centar za poljoprivredu, hranu i selo (2017, a), obrada autora

U dijelu poslovanja vinarija i izvora financiranja u 2009. godini zabilježena je najviša razina kamatnih stopa banaka na kunske kredite bez valutne klauzule od 9,69%, dok je stopa ispod 5% zabilježena u 2014. (4,75%) i 2015. (4,40%) godini. Kamatne stope na kunske kredite s valutnom klauzulom trgovačkim društvima kretale su se od 5,84% u 2015. do 7,71% u 2009. godini. U 2008. i 2009. zabilježene su najviše kamatne stope od 7,06% i 7,21%, dok su u 2014. i 2015. zabilježene najniže stope od 4,79% i 4,38%. Tečaj eura kretao se od najnižeg, 7,31, u 2009. godini do 7,66 u 2014. godini (Hrvatska narodna banka, 2016, a, b) (slika 10).



Slika 10: Promjena kamatnih stopa i srednjeg tečaja eura u razdoblju od 2005. do 2015.

Izvor: Hrvatska narodna banka, (2016, a, b), obrada autora

Većina komercijalnih banaka ima i dodatne linije financiranja koje se temelje na ugovorima o poslovnoj suradnji s ministarstvima, HBOR-om, HAMAG-BICRO-m, jedinicama lokalne samouprave, gradovima, županijama te međunarodnim financijskim institucijama (EBRD - Europska banka za obnovu i razvoj, EIB - Europska investicijska banka, CEB – Razvojna banka Vijeća Europe, EFSE - Europski fond za Jugoistočnu Europu, EIF - Europski investicijski fond i dr.). Vlada Republike Hrvatske potiče razvoj sektora malih i srednjih poduzeća kroz dodjelu bespovratnih sredstava (potpora) te subvencioniranje kamata na kredite namijenjene započinjanju i razvoju poduzetničke aktivnosti (Alpeza i sur., 2017).

Izvor financijskih sredstava su i europski fondovi. Financijske mogućnosti koje nude mogu pomoći u opremanju i razvoju vinarija. Jedan od velikih izazova za prijavitelje projektnih prijedloga predstavlja i njihova priprema za natječaje, a s tim u vezi je i potreba strateškog promišljanja o razvoju vinarije upravo kroz pojedine projekte.

Europski fondovi zamišljeni su kao financijski instrumenti koji podupiru provedbu pojedine politike Europske unije u zemljama članicama. U financijskoj perspektivi od 2014. do 2020. na raspolaganju je pet fondova pod nazivom Europski strukturni i investicijski fondovi (ESI). ESI fondovi uključuju Europski fond za regionalni razvoj (ERDF), Kohezijski fond, Europski socijalni fond (ESF), Europski poljoprivredni fond za ruralni razvoj (ERDF) i Europski fond za pomorstvo i ribarstvo (ERDF). Zajednička poljoprivredna politika Europske Unije (ZPP) temelji se na dva stupa: tržišnoj politici (potpora za povećanje prihoda) te politici ruralnog razvoja (javna dobra). Prvi se stup financira iz Europskog fonda za jamstva u poljoprivredi (ERDF) koji osigurava izravnu financijsku pomoć poljoprivrednicima u zemljama članicama. Drugi se stup financira iz Europskog poljoprivrednog fonda za ruralni razvoj (ERDF) koji je usmjeren na financiranje programa za ruralni razvoj. U financijskom paketu Europskog fonda za jamstva u poljoprivredi za Republiku Hrvatsku očekuje se oko 373 milijuna eura godišnje za izravna plaćanja. Osim osnovne omotnice, za Republiku Hrvatsku osigurana je i dodatna vinska omotnica u visini 10,8 milijuna eura godišnje (Ministarstvo regionalnog razvoja i fondova Europske unije Republike Hrvatske, 2012, a, b, c).

Proizvođačima i poslovnim subjektima u sektoru vinogradarstva i vinarstva pruža se mogućnost tržišne potpore u obliku vinske omotnice temeljem Nacionalnog programa pomoći sektoru vina 2014. - 2018. i mjera ruralnog razvoja. Nacionalni program pomoći sektoru vina od 2014. do 2018. obuhvaća mjere investicija u vinarije i marketing vina, promidžbe vina na tržištima trećih zemalja i restrukturiranja i konverzije vinograda (Ministarstvo poljoprivrede Republike Hrvatske, 2008).



Za poslovanje vinarija izazov je i porezno opterećenje. Hrvatski porezni sustav razlikuje pet skupina poreza: državne, županijske, gradske ili općinske, zajedničke i poreze na dobitke od igara na sreću te naknade na priređivanje igara na sreću (Ministarstvo financija Republike Hrvatske Porezna uprava, 2016). Regulativu poreznog sustava čine sljedeći zakoni: Opći porezni zakon, Zakon o doprinosima, Zakon o porezu na dobit, Zakon o porezu na dohodak, Zakon o porezu na dodanu vrijednost, Zakon o porezu na promet nekretnina, Zakon o trošarinama. Temeljni zakon carinskog sustava je Zakon o provedbi carinskih propisa Europske unije. Glavna porezna opterećenja za poduzeća u Hrvatskoj su porez na dodanu vrijednost, porez na dohodak, porez na dobit te prirez (prihod lokalnih zajednica - općina i gradova). U kategoriji plaćanja poreza, prema rezultatima *Doing Business* 2016 poraslo je ukupno porezno opterećenje poduzetnika sa 18,4% u 2014. godini na 20% u 2015. godini. Broj poreza koji se moraju platiti tijekom godine je 19, kao i prethodnih godina. Za usporedbu, Njemačka i Slovenija imaju manji broj poreza, ali je potrebno više vremena za pripremu i plaćanje poreza, a više su stope poreza na dobit (Alpeza i sur., 2017).

### 5.2.3. Analiza poslovanja i financijski rizici vinarija

U razdoblju od 2011./2012. do 2014./2015. godine broj poslovnih subjekata koji je za područje i razred djelatnosti naznačio prerađivačku industriju i proizvodnju vina od grožđa povećao se sa 172 poslovna subjekta na 207, odnosno za 20% (tablica 36).

Tablica 36: Broj poslovnih subjekata s dostupnim podacima u FINA-i

Broj subjekata	2011. i 2012.	2012. i 2013.	2013. i 2014.	2014. i 2015.	Indeks stupac 5/2
1	2	3	4	5	6
Ukupno	172	193	207	207	120,35

Izvor: FINA (2016), obrada autora

Detaljna analiza podataka napravljena je za sve poslovne subjekte koji su imali financijske izvještaje (bilancu stanja, račun dobiti i gubitka) dostupne za svaku godinu razdoblja od 2011. do 2015. Takvih je poslovnih subjekata bilo 95.

Najveći broj poslovnih subjekata bio je iz Istarske (17), Dubrovačko-neretvanske (17) i Splitsko-dalmatinske (14) županije. Prema veličini poslovnih subjekata, najveći broj subjekata su mali subjekti (91). U promatranom razdoblju jedan je poslovni subjekt u 2011./2012. bio u kategoriji „velikog“ poduzetnika, ali je tijekom sljedećeg razdoblja bio u kategoriji „srednje velikog“ poduzetnika. Prema vrsti vlasništva, 76 poslovnih subjekata bilo je u privatnom vlasništvu, 1 poslovni subjekt bio je 2011./2012. i 2012./2013. godine u mješovitom vlasništvu s pretežno državnim kapitalom (više od 50%) i 1 poslovni subjekt bio je 2011./2012. u zadružnom vlasništvu, ali nakon toga prelaze u privatno vlasništvo. Prema

udjelu domaćeg kapitala, 87 poslovnih subjekata imalo je 100% domaći kapital i 7 poslovnih subjekata imalo je 100% „ino“ kapital. Tijekom promatranog razdoblja najveći broj poslovnih subjekata posluje bez zaposlenih ili, u 2012. godini, bez zaposlenih ili s jednim zaposlenikom (tablica 37, tablica 38, tablica 39, tablica 40, tablica 41).

Tablica 37: Poslovni subjekti prema županijama

Županija	Šifra	Broj poslovnih subjekata	Udio
Zagrebačka	1	4	4,21
Krapinsko-zagorska	2	2	2,11
Sisačko-moslavačka	3	3	3,16
Varaždinska	5	1	1,05
Koprivničko-križevačka	6	1	1,05
Bjelovarska	7	-	-
Primorsko-goranska	8	5	5,26
Virovitičko-podravska	10	2	2,11
Požeško-slavonska	11	5	5,26
Brodsko-posavska	12	1	1,05
Zadarska	13	3	3,16
Osječko-baranjska	14	7	7,37
Šibensko-kninska	15	2	2,11
Vukovarsko-srijemska	16	3	3,16
Splitsko-dalmatinska	17	14	14,74
Istarska	18	17	17,89
Dubrovačko-neretvanska	19	17	17,89
Međimurska	20	6	6,32
Grad Zagreb	21	2	2,11
<b>Ukupno</b>		<b>95</b>	<b>100,00</b>

Izvor: FINA (2016), obrada autora

Tablica 38: Poslovni subjekti prema veličini poduzetnika

Veličina	Šifra	Broj poslovnih subjekata	Udio
Mali poduzetnik	1	91	95,79
Srednje veliki poduzetnik	2	4	4,21
Veliki poduzetnik	3	-	-
<b>Ukupno</b>		<b>95</b>	<b>100,00</b>

Izvor: FINA (2016), obrada autora

Tablica 39: Poslovni subjekti prema vlasništvu

Vlasništvo	Šifra	Broj poslovnih subjekata	Udio
Privatno vlasništvo od osnivanja	21	76	80,00
Privatno vlasništvo nakon pretvorbe	22	3	3,16
Zadružno vlasništvo	31	11	11,58
Mješovito vlasništvo s pretežno privatnim kapitalom (više od 50%)	41	3	3,16
Mješovito vlasništvo s pretežno državnim kapitalom (više od 50%)	42	2	2,11
<b>Ukupno</b>		<b>95</b>	<b>100,0</b>

Izvor: FINA (2016), obrada autora

Tablica 40: Poslovni subjekti prema udjelu domaćeg kapitala

Domaći kapital (%)	Broj poslovnih subjekata	Udio
0	7	7,4
5	1	1,1
100	87	91,6
<b>Ukupno</b>	<b>95</b>	<b>100,0</b>

Izvor: FINA (2016), obrada autora

Tablica 41: Poslovni subjekti prema broju zaposlenih

Broj zaposlenih	2011.	2012.	2013.	2014.	2015.	Indeks 2015./2011.
više od 100	3	3	2	1	1	33,33
od 10 do 100 zaposlenika	16	18	17	18	20	125,00
od 5 do 9 zaposlenika	14	12	13	16	13	92,86
od 2 do 4 zaposlenika	14	16	20	18	15	107,14
1 zaposlenik	18	23	19	13	17	94,44
bez zaposlenika	30	23	24	29	29	96,67
<b>Ukupno</b>	<b>95</b>	<b>95</b>	<b>95</b>	<b>95</b>	<b>95</b>	<b>100,00</b>

Izvor: FINA (2016), obrada autora

Prema pravnom obliku poslovnih subjekata, a što je moguće zaključiti iz naziva poslovnog subjekta, bilo je 64,21% društava ograničene odgovornosti, 17,89% poljoprivrednih zadruga, 7,37% dioničkih društava i 10,53% poslovnih subjekata koji su svrstani u kategoriju „ostalo“ (tablica 42). Dodatno su dodijeljene šifre subjektima s obzirom na pravni status iz naziva poslovnog subjekta.

Tablica 42: Poslovni subjekti prema pravnom statusu naznačenom u nazivu subjekta

Vrsta poslovnog subjekta	Šifra	Broj poslovnih subjekata	Udio
D.D.	1	7	7,37
D.o.o.	2	61	64,21
Poljoprivredna zadruga, zadruga	3	17	17,89
Ostalo (OPG, obrt, vinogradarstvo i podrumarstvo, ostalo)	4	10	10,53
<b>Ukupno</b>		<b>95</b>	<b>100,00</b>

Izvor: FINA (2016), obrada autora

U analizi bilance stanja, promatrajući 2015. i 2011. došlo je do pada srednje vrijednosti ukupne imovine (aktive) odnosno ukupnog kapitala i obveza (pasive) bilance stanja za 2,62%, s 13,356 milijuna kuna na 13,006 milijuna kuna. Najniža srednja vrijednost aktive odnosno pasive promatranih poslovnih subjekata od 11,967 milijuna kuna zabilježena je u 2014. godini.

U istom razdoblju, od 2011. do 2015., smanjena je i vrijednost dugotrajne imovine za 7,47% i povećana je vrijednost kratkotrajne imovine za 5,02%. Dugotrajna je imovina u prosjeku imala udio u aktivi, 60,75%, a kratkotrajna 39,16%.

Vinarije u Republici Hrvatskoj investiraju u građevinske objekte i zemljište. Unutar dugotrajne imovine, građevinski objekti imali su najveći prosječni udio (31,19%), nakon čega slijedi vrijednost zemljišta (30,68%), postrojenja i oprema od 8,90% i biološke imovine od 10,91%.

Vrijednost kapitala i rezervi povećala se za 22,55%, ali u negativnom kontekstu. U 2015. godini u odnosu na 2011. godinu raslo je i zaduživanje poslovnih subjekata, dugoročne obveze porasle su za +7,41% i kratkoročne obveze za +5,81%. Prosječna vrijednost dugoročnih obveza kretala se od 3,177 milijuna kuna u 2011. godini do 3,412 milijuna kuna u 2015. godini. Vrijednost kratkoročnih obveza kretala se od 16,406 milijuna kuna u 2011. godini do 17,360 milijuna kuna u 2015. godini i bila je veća od ukupne vrijednosti kapitala i obveza (tablica 43).

Tablica 43: Odabrane stavke bilance za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)


Godina	Dugotrajna imovina	Kratkotrajna imovina	Kapital i rezerve	Dugoročne obveze	Kratkoročne obveze	Ukupno aktiva/pasiva
2011.	8.171.652	5.174.591	-6.365.794	3.177.254	16.406.978	13.356.247
2012.	8.171.195	4.835.857	-7.408.262	3.362.623	16.995.708	13.019.709
2013.	7.528.541	4.813.730	-7.888.268	3.326.596	16.856.315	12.355.337
2014.	7.265.734	4.685.157	-7.892.257	3.206.798	16.597.986	11.967.466
2015.	7.561.559	5.434.452	-7.801.528	3.412.679	17.360.367	13.006.462
Indeks 2015./2011.	92,53	105,02	122,55	107,41	105,81	97,38

Izvor: FINA (2016), obrada autora

U analizi računa dobiti i gubitka u razdoblju od 2011. do 2015. godine, ukupni prihodi povećani su u 2015. godini za 4,68%, s 3,562 milijuna kuna na 3,729 milijuna kuna. U 2014. godini zabilježena je najviša srednja vrijednost ukupnih prihoda, 4,229 milijuna kuna. U strukturi ukupnih prihoda, prihodi od prodaje čine u prosjeku 83,26% poslovnih prihoda.

Prosječna godišnja dobit ili gubitak kretala se od -1.928.442,76 HRK u 2011. do 55.706,45 u 2014. godini i -653.234,99 u 2015. godini. Prema ukupnoj prosječnoj vrijednosti za petogodišnje razdoblje, 47 poslovnih subjekata poslovalo je s dobitkom.

U 2015. godini u odnosu na 2011. godinu smanjeni su ukupni rashodi za 20,52%, s 5,486 milijuna kuna na 4,360 milijuna kuna. U strukturi rashoda u prosjeku su najznačajniji materijalni troškovi s udjelom od 50,83% i troškovi osoblja s udjelom od 16,64%. Tijekom razdoblja, osim u 2014. godini, zabilježeni su gubici ukupne prosječne vrijednosti promatranih poslovnih subjekata. Ukupna prosječna dobit za promatrano razdoblje bila je 226.420,30 HRK, a prosječni gubitak 959.384,54 kuna (graf 7).



Graf 7: Ukupni prihodi i rashodi te dobit ili gubitak za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora

U horizontalnoj analizi podataka od 2011. do 2015. promatrane su srednje vrijednosti pokazatelja likvidnosti, razina zaduženosti, pokazatelja profitabilnosti i Altmanov A-Z-score.

Od ukupno 95 poslovnih subjekata, srednja godišnja vrijednost koeficijenta tekuće likvidnosti kretala se od 2,57 u 2011. godini do 3,44 u 2015. godini.

Koeficijent tekuće likvidnosti za male poslovne subjekte bio je u prosjeku 2,91, dok je za srednje velike poslovne subjekte bio 1,36.

Kod dioničkih društava tijekom promatranog razdoblja zabilježena je najniža srednja vrijednost koeficijenta tekuće likvidnosti od 1,32.


Srednja godišnja vrijednost koeficijenta ubrzane likvidnosti kretala se od 1,51 u 2011. do 1,81 u 2015.

Kod malih poslovnih subjekata srednja vrijednost koeficijenta bila je 1,59, dok je kod srednje velikih poslovnih subjekata koeficijent bio 0,83. Dionička društva imala su najnižu srednju vrijednost koeficijenta, 0,64.

Srednja godišnja vrijednost koeficijenta financijske stabilnosti promatranih poslovnih subjekata kretala se od 0,45 u 2011. godini do 2,45 u 2015. godini. Kod malih poslovnih subjekata srednja vrijednost koeficijenta iznosila je 1,48, a kod srednje velikih 0,40. Dionička društva imala su najnižu srednju vrijednost koeficijenta, -0,61.


Od 2011. do 2015. godine srednja godišnja vrijednost razine zaduženosti kretala se od 0,81 do 1,05. Kod srednje velikih poduzeća srednja vrijednost koeficijenta iznosila je 2,51, dok je kod malih iznosila 0,91. U promatranom razdoblju, dionička društva imala su najvišu razinu zaduženosti, 1,85.

Vrijednost pokazatelja profitabilnosti, ROA, kretala se od -0,05 u 2011. do -0,04 u 2015. Srednje velika poduzeća imala su srednju vrijednost pokazatelja -0,09, dok su mala poduzeća imala srednju vrijednost pokazatelja -0,10. U razdoblju od 2011. do 2015. dionička društva imala su vrijednost pokazatelja od -0,06. Vrijednost ROE kretala se od 0,09 u 2011. godini do 0,12 u 2015. godini. Za srednje velika poduzeća srednja vrijednost ROE bila je -0,83, dok je za mala poduzeća vrijednost iznosila 0,08. U promatranom razdoblju, dionička društva imala su najnižu vrijednost ROE, -0,47 (tablica 44, tablica 45, graf 9).



Graf 8: Financijski pokazatelji poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora



Graf 9: ROA i ROE poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora

Tablica 44: Financijski pokazatelji poslovnih subjekata prema veličini za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Veličina poduz.	Tekuća likv.	Ubrzana likv.	Fin. stab.	Koeficijent zaduženost	ROA	ROE	Altman A-Z-score
Srednje veliki	1,36	0,83	0,40	2,51	-0,09	-0,83	-3,09
Mali	2,91	1,59	1,48	0,91	-0,10	0,08	1,15

Izvor: FINA (2016), obrada autora


Tablica 45: Financijski pokazatelji poslovnih subjekata prema nazivu za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Opis	Tekuća likv.	Ubrzana likv.	Fin. stab.	Koeficijent zaduženosti	ROA	ROE	Altman A-Z-score
D.D.	1,32	0,64	-0,61	1,85	-0,06	-0,47	-1,99
D.O.O.	3,00	1,75	0,44	1,07	-0,16	0,09	0,93
P.Z., zadruga	2,68	1,34	6,04	0,55	0,0006	0,02	2,07
OSTALI	3,24	1,44	1,14	0,58	0,02	0,19	1,42

Izvor: FINA (2016), obrada autora

Prosječne vrijednosti za Altmanov A-Z-score modela svih poslovnih subjekata kretale su se od 1,06 u 2011. godini do 1,46 u 2015. godini.

Kod malih poslovnih subjekata srednja vrijednost koeficijenta iznosila je 1,15, a kod srednje velikih poslovnih subjekata, vrijednost je iznosila -3,09. Dionička društva su imala najnižu vrijednost koeficijenta od -1,99, dok su poljoprivredne zadruge imale najvišu vrijednost od 2,07 (tablica 44, tablica 45, graf 10).



Graf 10: Altmanov A-Z-score poslovnih subjekata (srednja vrijednost, n = 95 poslovnih subjekata) za razdoblje od 2011. do 2015.

Izvor: FINA (2016), obrada autora

U pregledu poslovnih subjekata prema Altmanovom A-Z-score-u, najveći broj poslovnih subjekata imao je prosječnu srednju vrijednost manju od 1,23. Rizik od stečaja vrlo je velik kod 43 poduzeća registrirana kao društvo ograničene odgovornosti, 59 malih poduzeća, 54 poduzeća privatnog vlasništva od osnivanja, 56 poduzeća s u cijelosti domaćim kapitalom, 26 poduzeća s manje od 10 zaposlenih i 38 poduzeća s područja primorske Hrvatske (tablica 46).



Tablica 46: Poslovni subjekti prema obilježju poslovanja i vrijednostima Altmanovog A-Z-score-a (srednja vrijednost, n = 95 poslovnih subjekata)

Opis	$\geq 2,9$	2,89-2,69	2,68-1,24	1,23 $\geq$	Ukupno
D.D.				7	7
D.O.O.	5		12	43	60
Poljoprivredne zadruge, zadruge	4		4	9	17
Ostali			6	4	10
Srednje velika poduzeća				4	4
Mala poduzeća	9		22	59	90
Privatno vlasništvo od osnivanja	4		20	54	78
Privatno vlasništvo nakon pretvorbe					
Zadružno vlasništvo	4		2	5	11
Ostalo (mješovito vlasništvo s pretežno privatnim kapitalom i pretežno državnim kapitalom)	1			4	5
Domaći kapital 100%	9		21	56	86
Ostalo			1	7	8
Bez zaposlenih	2		5	22	29
Manje od 10 zaposlenih	7		11	26	44
Od 10 do 100 zaposlenih			6	14	20
Više od 100 zaposlenih				1	1
Kontinentalna	2		10	25	37
Primorska	7		12	38	57

Napomena: Jedan poslovni subjekt koji je registriran d.o.o. pripada malim poduzećima, u privatnom je vlasništvu od osnivanja, u cijelosti s domaćim kapitalom, bez zaposlenika i iz primorske RH, nije uključen u obradu zbog nemogućnosti izračuna pokazatelja.

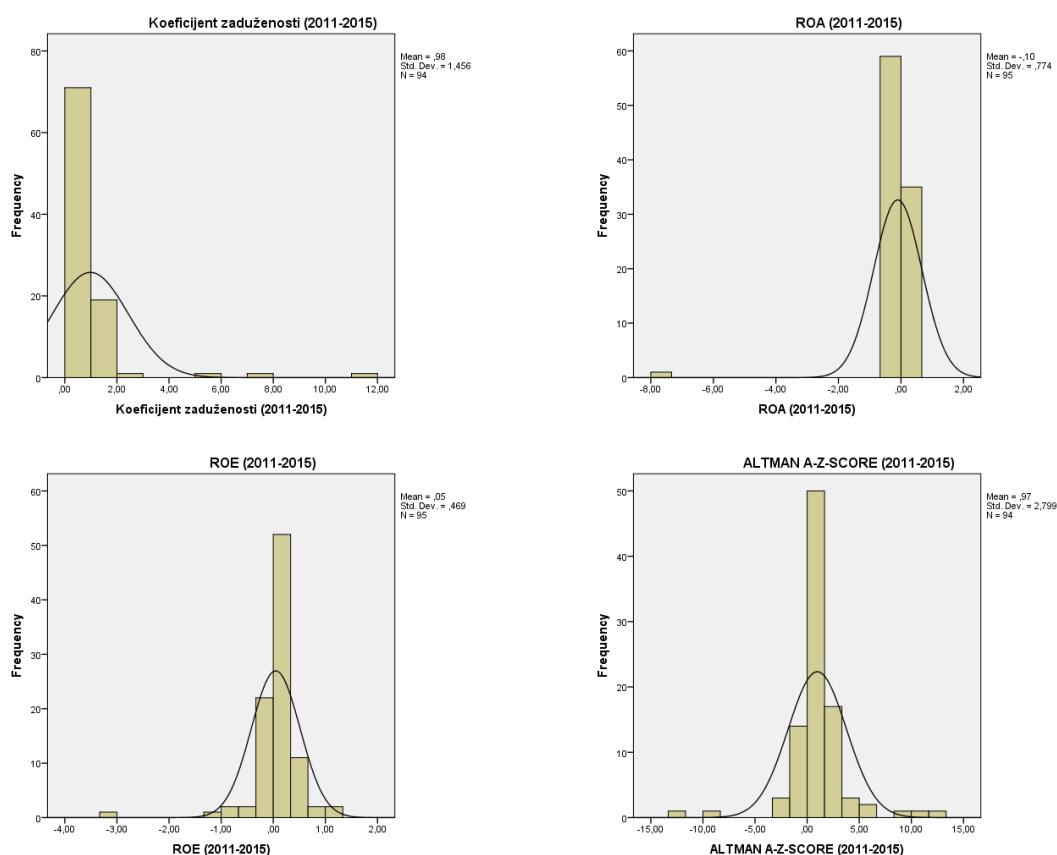
Izvor: FINA (2016), obrada autora

Kod financijskog rizika analizirana je promjena zaduženosti, ROA, ROE te Altmanov A-Z-score za vinarije u Hrvatskoj.

Prosječne vrijednosti razine zaduženosti u promatranom razdoblju za 94 poslovna subjekta kretale su se od 0,05 do 11,77, uz jedan *outlier* koji nije uključen u analizu.

Za ROA prosječna vrijednost imala je vrijednosti od -7,4 do 0,19, i za ROE imala je vrijednosti od -3,14 do 1,18.

Vrijednosti A-Z-score-a kretale su se od -12,37 do 12,16. U analizu nije uključen jedan *outlier* (slika 11).



Slika 11: Razina zaduženosti, ROA, ROE i Altmanov A-Z-score u razdoblju od 2011. do 2015. (srednja vrijednost)

Izvor: FINA (2016), obrada autora

Analiza poslovanja uključivala je i provođenje višestruke i jednostavne linearne regresije.

Rezultati primjene modela višestruke regresije na analizi  $n = 95$  pokazali su da *dummy* varijable „županija“ i „domaći kapital“ nisu statistički značajne.

Od modela višestruke regresije napravljena je usporedba ukupnog prihoda (zavisne varijable) i broja zaposlenih, materijalnih troškova, troškova osoblja i županije (nezavisne varijable). Županija je bila *dummy* varijabla i nije statistički značajna u modelu (uz razinu signifikantnosti testa 5%). Ostale nezavisne varijable statistički su značajne.

Kad se isključi *dummy* varijabla županija, ukupan prihod (zavisna varijabla) i broj zaposlenih, materijalni troškovi, troškovi osoblja (nezavisna varijabla), model višestruke linearne regresije s procijenjenim parametrima je sljedeći:

$$\hat{y}_i = 3696532 - 111089,2x_{i1} + 1,222366x_{i2} + 2,379972x_{i3}$$

Tablica 47: Regresija ukupnog prihoda (zavisne varijable) i nezavisnih varijabli ( $n = 95$ )

Dependent Variable: UP

Method: Least Squares

Sample: 1 95

Included observations: 95

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	369653.2	285012.3	1.296973	0.1979
BZ	-111089.2	41711.57	-2.663270	0.0092
MT	1.222366	0.149242	8.190479	0.0000
TO	2.379972	0.802734	2.964832	0.0039
R-squared	0.901057	Mean dependent var		3722653.
Adjusted R-squared	0.897795	S.D. dependent var		7773032.
S.E. of regression	2484997.	Akaike info criterion		32.33063
Sum squared resid	5.62E+14	Schwarz criterion		32.43817
Log likelihood	-1531.705	Hannan-Quinn criter.		32.37409
F-statistic	276.2409	Durbin-Watson stat		1.366637
Prob(F-statistic)	0.000000			

Izvor: FINA (2016), ispis iz EViews 7.0

Kada se broj zaposlenih poveća za 1, uz nepromijenjene ostale nezavisne varijable, ukupni će se prihod u prosjeku smanjiti za 111.089,2 kuna. Kada se materijalni troškovi povećaju za 1 kunu, uz nepromijenjene ostale nezavisne varijable, ukupni će se prihod u prosjeku povećati za 1,22 kuna.

Kada se trošak osoblja poveća za jednu kunu, uz nepromijenjene ostale nezavisne varijable, ukupni će se prihod u prosjeku povećati za 2,38 kune.

Sve nezavisne varijable statistički su značajne u modelu, odnosno statistički značajno objašnjavaju varijacije ukupnog prihoda. Provedeni su jednosmjerni testovi značajnosti nezavisnih (regresorskih) varijabli u modelu. Testovi su provedeni uz razinu signifikantnosti testa 5%. Zaključci o značajnosti nezavisnih varijabli doneseni su usporedbom empirijske i teorijske razine signifikantnosti testa (p-vrijednost), kako je dano u tablici 47.

Da bi se izmjerio relativni utjecaj triju nezavisnih varijabli na ukupni prihod, procijenjen je model višestruke regresije sa standardiziranim varijablama (prilog 33).

Model s procijenjenim parametrima je sljedeći:

$$\hat{y}_i^* = -0,438614 x_{i1}^* + 0,761621 x_{i2}^* + 0,61426 x_{i3}^*$$

Kada se broj zaposlenih poveća za jednu standardnu devijaciju, uz nepromijenjene materijalne troškove i troškove osoblja, ukupni će se prihod u prosjeku smanjiti za 0,44 standardne devijacije. Povećanje troškova osoblja za jednu standardnu devijaciju, uz nepromijenjen broj zaposlenih i materijalne troškove, rezultira povećanjem ukupnih prihoda u prosjeku za 0,61 standardnu devijaciju. Povećanje materijalnih troškova za jednu standardnu devijaciju, uz nepromijenjen broj zaposlenih i troškove osoblja, utjecat će na povećanje ukupnih prihoda prosječno za 0,76 standardnih devijacija.

Usporedbom procijenjenih parametara lako se uoči da povećanje broja zaposlenih negativno utječe na promjenu ukupnog prihoda, dok povećanje materijalnih troškova i troškova osoblja utječe pozitivno. Također se uočava da je (po apsolutnoj vrijednosti) najveći procijenjeni parametar u jednadžbi sa standardiziranim varijablama onaj uz materijalne troškove (0,761621). To znači da je relativni utjecaj materijalnih troškova na ukupni prihod veći od utjecaja troškova osoblja i broja zaposlenih. To bi za posljedicu moglo imati i veći rizik. Materijalni su troškovi rizičnija varijabla od ostalih.

U drugom modelu regresiran je ukupan prihod (zavisna varijabla) i broj zaposlenih, materijalni troškovi, troškovi osoblja, pravni status (nezavisne varijable). Sve nezavisne varijable statistički su značajne u modelu, odnosno statistički značajno objašnjavaju varijacije ukupnog prihoda. Provedeni su jednosmjerni testovi značajnosti nezavisnih (regresorskih) varijabli u modelu. Testovi su provedeni uz razinu signifikantnosti testa 5%. *Dummy* varijabla „pravni status“ statistički je značajna u modelu. Model višestruke linearne regresije s procijenjenim parametrima i statistički značajnom *dummy* varijablom „pravni status“ je sljedeći:

$$\hat{y}_i = 6034622 - 88067,50x_{i1} + 1,308657x_{i2} + 1,313588x_{i3} - 5735731x_{i4}$$

Rezultati analize navedenog modela višestruke regresije, s procijenjenim parametrima, prezentirani su u tablici 48, kako slijedi.

Tablica 48: Regresija ukupnog prihoda (zavisne varijable) i nezavisnih varijabli (n = 95)

Dependent Variable: UP

Method: Least Squares

Sample: 1 95

Included observations: 95

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	6034622.	1275603.	4.730799	0.0000
BZ	-88067.50	38180.01	-2.306639	0.0234
MT	1.308657	0.136724	9.571512	0.0000
TO	1.313588	0.765266	1.716512	0.0895
PS	-5735731.	1264725.	-4.535159	0.0000
R-squared	0.919462	Mean dependent var		3722653.
Adjusted R-squared	0.915883	S.D. dependent var		7773032.
S.E. of regression	2254408.	Akaike info criterion		32.14587
Sum squared resid	4.57E+14	Schwarz criterion		32.28028
Log likelihood	-1521.929	Hannan-Quinn criter.		32.20018
F-statistic	256.8725	Durbin-Watson stat		1.618311
Prob(F-statistic)	0.000000			

Izvor: FINA (2016), ispis iz EViews 7.0

U odnosu na prethodna pojašnjenja, dodano je tumačenje procijenjenog parametra uz *dummy* varijablu „pravni status“. Uz nepromijenjene vrijednosti nezavisnih varijabli u modelu i pravni status u kojem je vinarija d.o.o., očekivana razlika ukupnog prihoda prema očekivanom prihodu u ostalim pravnim statusima vinarija iznosi -5.735.731 kuna.

U procijenjenom modelu, sve nezavisne varijable statistički su značajne uz razinu signifikantnosti testa 5% (jednosmjerni testovi).

Zaključak o relativnom utjecaju nezavisnih varijabli na ukupni prihod isti je kao i na temelju ranije prezentiranog modela sa standardiziranim vrijednostima varijabli (prilog 34).

Model višestruke regresije sa standardiziranim varijablama:

$$\hat{y}_i^* = -0,347717 x_{i1}^* + 0,815387 x_{i2}^* + 0,339031 x_{i3}^* - 0,193804 x_{i4}^*$$

Kada se broj zaposlenih poveća za jednu standardnu devijaciju, uz nepromijenjene materijalne troškove i troškove osoblja i pravni status, ukupni će se prihod u prosjeku smanjiti za 0,35 standardnih devijacija. Povećanje materijalnih troškova za jednu standardnu devijaciju, uz nepromijenjen broj zaposlenih i troškove osoblja i pravni status, rezultirat će povećanjem ukupnog prihoda prosječno za 0,82 standardnih devijacija. Kada se troškovi osoblja povećaju za jednu standardnu devijaciju, uz nepromijenjen broj

zaposlenih i materijalne troškove i pravni status, ukupni će se prihod u prosjeku povećati za 0,34 standardnu devijaciju. Uz nepromijenjene varijable broj zaposlenih, materijalni troškovi, troškovi osoblja i za pravni status d.o.o. očekivana razlika ukupnog prihoda u odnosu na ostale oblike pravnog statusa je -0,19 standardnih devijacija. I dalje je (po apsolutnoj vrijednosti) najveći procijenjeni parametar u jednadžbi sa standardiziranim varijablama onaj uz materijalne troškove (0,815387). To znači da je relativni utjecaj materijalnih troškova na ukupni prihod veći od utjecaja ostalih nezavisnih varijabli u modelu. To bi za posljedicu moglo imati i veći rizik.

U trećem modelu regresiran je ukupan prihod (zavisna varijabla) i broj zaposlenih, materijalni troškovi, troškovi osoblja, veličina (nezavisne varijable). *Dummy* varijabla „veličina“ statistički je značajna u modelu. Rezultati regresijske analize dani su u tablici 49. Model višestruke linearne regresije s procijenjenim parametrima i statistički značajnom *dummy* varijablom „veličina“ je sljedeći:

$$\hat{y}_i = 17387248 - 1336623x_{i1} + 1,22055x_{i2} + 1,29102x_{i3} - 16674888x_{i4}$$

Tablica 49: Regresija ukupnog prihoda (zavisne varijable) i nezavisnih varijabli (n = 95)

Dependent Variable: UP

Method: Least Squares

Sample: 1 95

Included observations: 95

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	17387248	1754102.	9.912337	0.0000
BZ	-133662.3	29317.50	-4.559132	0.0000
MT	1.220551	0.104570	11.67205	0.0000
TO	1.291021	0.573403	2.251505	0.0268
V	-16674888	1707602.	-9.765092	0.0000
R-squared	0.951958	Mean dependent var		3722653.
Adjusted R-squared	0.949823	S.D. dependent var		7773032.
S.E. of regression	1741174.	Akaike info criterion		31.62921
Sum squared resid	2.73E+14	Schwarz criterion		31.76363
Log likelihood	-1497.388	Hannan-Quinn criter.		31.68353
F-statistic	445.8435	Durbin-Watson stat		1.838573
Prob(F-statistic)	0.000000			

Izvor: FINA (2016), ispis iz EViews 7.0

U procijenjenom su modelu sve nezavisne varijable statistički značajne, uz razinu signifikantnosti testa 5%. Uz nepromijenjene vrijednosti nezavisnih varijabli u modelu i varijablu „veličina“ koja znači da je vinarija mala, očekivana razlika ukupnog prihoda prema očekivanom prihodu u ostalim veličinama vinarija iznosi -16.674.888 kuna.

Relativni utjecaj nezavisnih varijabli na ukupni prihod prikazan je, na već ranije objašnjen način, u modelu višestruke regresije sa standardiziranim varijablama. Model s procijenjenim parametrima je sljedeći:

$$\hat{y}_i^* = -0,527739 x_{i1}^* + 0,760491 x_{i2}^* + 0,333207 x_{i3}^* - 0,433109 x_{i4}^*$$

Uz nepromijenjene nezavisne varijable: broj zaposlenih, materijalni troškovi, troškovi osoblja, a za veličinu koja predstavlja male vinarije, očekivana razlika ukupnog prihoda u odnosu na ostale veličine vinarija je -0,43 standardnih devijacija (prilog 35). I dalje je (po apsolutnoj vrijednosti) najveći procijenjeni parametar u jednadžbi sa standardiziranim varijablama onaj uz materijalne troškove (0,760491). To znači da je relativni utjecaj materijalnih troškova na ukupni prihod veći od utjecaja ostalih nezavisnih varijabli u modelu.

U četvrtom modelu regresiran je ukupan prihod (zavisna varijabla) i broj zaposlenih, materijalni troškovi, troškovi osoblja, domaći kapital (nezavisne varijable). Varijabla domaći kapital nije bila statistički značajna u modelu.

Nakon analize modela višestruke regresije provedena je analiza modela u kojima je ukupni prihod definiran kao zavisna varijabla, a nezavisne varijable su, jedna po jedna, uključivane u modele, uvijek zajedno s jednom *dummy* varijablom. U prvom slučaju regresiran je ukupan prihod (zavisna varijabla) i broj zaposlenih (nezavisna varijabla). *Dummy* varijable „pravni status“ i „veličina“ bile su u modelima statistički značajne varijable. U modelima ne postoji problem multikolinearnosti. „Županija“ i „domaći kapital“ nisu statistički značajne varijable<sup>3</sup>. U drugom slučaju regresiran je ukupni prihod (zavisna varijabla) i ukupni rashod (nezavisna varijabla). *Dummy* varijable „pravni status“ i „veličina“ i u ovim su modelima značajne varijable, dok varijable „županija“ i „domaći kapital“ nisu statistički značajne (prilog 36, prilog 37, prilog 38, prilog 39, prilog 40, prilog 41, prilog 42, prilog 43).

Na kraju je regresiran ukupni prihod (zavisna varijabla) i sve nezavisne varijable svaka posebno, bez *dummy* varijabli u modelima jednostavne linearne regresije. Procijenjeni parametri u regresijskom modelu sa standardiziranim varijablama u modelima jednostavne linearne regresije dani su u tablici 50.

---

<sup>3</sup> Detaljni rezultati statističke obrade dostupni na zahtjev autorici.

Tablica 50: Procijenjeni parametri u regresijskom modelu sa standardiziranim varijablama jednostavne linearne regresije

Nezavisne varijable	Standardizirani koeficijenti	
Broj zaposlenih	0.834850	
Ukupni rashod	0.902113	
Poslovni rashod	0.890289	
<b>Materijalni troškovi</b>	<b>0.944192</b>	<b>Najveći relativni utjecaj</b>
Trošak osoblja	0.892320	

Izvor: FINA (2016), ispis iz EViews 7.0

Materijalni troškovi pokazali su se i ovaj put kao najrizičnija varijabla koja najsnažnije utječe na ukupan prihod.

#### 5.2.4. Rangiranje vinarija prema stupnju rizika

Prema standardnoj devijaciji Altmanov A-Z-score rangirano je 95 vinarija u Hrvatskoj.


Za razdoblje od 2011. do 2015. godine bilo je 8 poslovnih subjekata kojima prijeti vrlo mali rizik od stečaja. Zajedničke karakteristike ovih poslovnih subjekata prema veličini to su mali poslovni subjekti, u privatnom, mješovitom vlasništvu s pretežno privatnim kapitalom ili zadružnom vlasništvu, 100% domaći kapital, s maksimalno 2 zaposlena ili bez zaposlenih. Ovi su poslovni subjekti s područja podregije Plešivica, Hrvatska Istra, Slavonija, Hrvatsko Podunavlje, Srednja i Južna Dalmacija i Hrvatsko Primorje.

Prema kriteriju srednje rizične vinarije, standardna devijacija pokazala je 10 poslovnih subjekata. To su većinom male vinarije u privatnom vlasništvu s gotovo 100% domaćim kapitalom do 15 zaposlenih, s područja podregija Hrvatsko Podunavlje, Zagorje - Međimurje, Slavonija, Srednja i Južna Dalmacija, Prigorje - Bilogora.

Analiza je pokazala da 75 poslovnih subjekata spada u visoko rizične vinarije, i to male vinarije (2 srednje velike) u privatnom vlasništvu od osnivanja, većinom sa 100% domaćeg kapitala, do najviše 46 zaposlenih i većinom s područja Srednje i Južne Dalmacije.

Dva poslovna subjekta bili su *outlieri* i nisu uključeni u obradu zbog nemogućnosti izračuna pokazatelja (graf 11).





Graf 11: Vinarije u Hrvatskoj prema rizičnosti (standardna devijacija 2011. - 2015., n = 95 poslovnih subjekata)


Izvor: FINA (2016), obrada autora

## 5.3. Strateško upravljanje rizikom

### 5.3.1. Model strateškog upravljanja rizikom

Nakon horizontalne analize financijskih pokazatelja cilj je bio ustanoviti učinkovitost strateškog upravljanja rizikom primjenom stohastičkih simulacija u scenarije poslovnog razvoja na primjeru hipotetske vinarije. Stohastičkim se simulacijama na modelu vinarije pokušalo istražiti najvažnije rizike s kojima se vinarije susreću i otkriti kolika je fleksibilnost u poslovanju, odnosno koliko pojava rizika utječe na poslovne rezultate, odnosno koja je vjerojatnost da rezultati budu negativni ili ispod lijevog repa razdiobe (5%). To su parametri koji određuju profil rizika vinarije.

Nakon što su utvrđeni izvori rizika i njihova distribucija prišlo se odabiru strategija za upravljanje rizikom. Vrijednost strateškog upravljanja rizikom je ta što smanjuje varijabilnost poslovanja i, u konkretnom slučaju, utječe na poboljšanje profila rizika (slika 12).



Slika 12: Ciklus analize odlučivanja, temeljem analize ankete „Strateško upravljanje rizikom vinarija u Hrvatskoj“, prilagođeno iz Njavro (2017)

Za simulaciju je pripremljen model vinarije. Model smo nazvali „Vinarija“ i izgradili smo ga na sljedećim pretpostavkama.

1. Vinarija po svojim poslovnim obilježjima, opisanima u temeljnim financijskim izvješćima, odgovara vinariji srednje veličine, registrirane kao društvo s ograničenom odgovornošću. U izradi modela hipotetske vinarije izračunana je srednja vrijednosti odabranih dijelova

financijskih izvještaja za društva ograničene odgovornosti (n = 61), za razdoblje od 2011. do 2015. godine. Vinarija ima sljedeće vrijednosti pokazatelja poslovanja:

Tablica 51: Vrijednosti odabranih pozicija bilance i računa dobiti i gubitka „Vinarije“, prosjek za razdoblje od 2011. do 2015.

Stavka iz temeljnih financijskih izvješća	Vrijednost, HRK
Dugotrajna imovina	2.409.839
Kratkotrajna imovina	2.029.224
Dugoročne obveze	2.300.000
Kratkoročne obveze	756.667
Ukupni prihodi (poslovni prihodi)	2.458.500
Troškovi poslovanja	1.837.821
EBITDA	620.679
EBIT	446.379
Neto dobit	167.503

2. Poslovanje „Vinarije“ simulirano je na statičkoj varijanti modela za razdoblje od 5 godina.

U statičkoj varijanti pošlo se od sljedećih pretpostavki:

- Prodajna cijena vina: 15,84 HRK/l (na temelju analize statističkih podataka o kretanju cijena vina u Hrvatskoj za razdoblje od 2011. do 2015.).
- Trošak proizvodnje vina (proizvodna cijena): 10,00 HRK/l (ekspertna procjena i rezultat Modela Vinograd).
- Kapacitet vinarije 300 tisuća litara i iskorištenost kapaciteta 50%.

3. Nastavno na elemente statičke varijante modela „Vinarije“ izračunani su pokazatelji poslovanja.

Od pokazatelja zaduženosti razmatran je omjer ukupnih obveza i ukupne aktive te ukupnih obveza i kapitala i rezervi. S obzirom na vrijednost koeficijenta od 69% može se zaključiti da je financijski rizik značajan. Vrijednost pokazatelja od 1,56, odnosno 156% ukazuje na veliku zaduženost. Vrijednost ROA od 4% ukazuje na visoki stupanj intenzivnosti imovine (tablica 52).

Tablica 52: Rezultati poslovanja vinarije (statički pod model), prosjek za razdoblje od 2011. do 2015.

Pokazatelji	Vrijednost, HRK
Neto dobit	167.502,85
Bruto dobit	229.378,56
EBIT	446.378,56
D/A	0,69
D/E	1,56
ROA	0,04
ROE	0,09
Altmanov A-Z-score	1,37
Neto dug/EBITDA	3,32

#### 4. „Vinarija“ - stohastički podmodel

Nakon statičkog izgrađen je i stohastički podmodel vinarije. Model je stohastički simulacijski model izrađen u @Risk softveru (dodatak Excel) uz primjenu Monte Carlo simulacije i 5.000 iteracija. U stohastičkom podmodelu „Vinarije“ razmatrani su sljedeći stohastički elementi: prodajna cijena vina, proizvodna cijena vina i stupanj iskorištenja kapaciteta (tablica 53). Prodajna cijena je formirana na temelju podataka za kvalitetno vino iz tablice 14.

Tablica 53: Stohastički elementi podmodela „Vinarije“


Prodajna cijena vina, HRK/l	=RiskNormal(19,08;2;RiskStatic(19,08))
Proizvodna cijena vina, HRK/l	=RiskTriang(10;11,23;14;RiskStatic(10))
Visina prodaje, litara (% iskorištenja kapaciteta)	=RiskTriang(140000;150000;210000)

Vrijednost ROA bila je 0,10 odnosno 10%, i vrijednost ROE bila je 0,17 odnosno 17%. S vrijednošću Altmanovog A-Z-score-a od 1,97, stohastički podmodel „Vinarija“ je u „sivom“ području, s rizikom od stečaja u roku od 2 godine (tablica 54).

Tablica 54: Rezultati stohastičkog modela, prosjek za razdoblje od 2011.do 2015.


Pokazatelj	Vrijednost, HRK
Neto dobit	693.490,40
Bruto dobit	866.669,10
EBIT	1.101.566,00
ROA	0,10
ROE	0,17
Altmanov A-Z-score	1,97

Kao polazište prikazani su grafovi modela „Vinarije“ neto dobiti, ROA, ROE i Altmanov A-Z-score (graf 12, graf 13, graf 14).




Graf 12: Neto dobit stohastičkog modela „Vinarije“

Izvor: ispis iz @Risk



Graf 13: ROA i ROE stohastičkog modela „Vinarije“

Izvor: ispis iz @Risk



Graf 14: Altman A-Z-score stohastičkog modela „Vinarije“

Izvor: ispis iz @Risk

### 5.3.2. Scenarijska analiza strategija za upravljanje rizikom


Na bazni stohastički podmodel „Vinarije“ i scenarij modernizacije i rasta kroz nova ulaganja razvijene su sljedeće strategije:

- Strategija troškovne fleksibilnosti,
- Strategija širenja na tržištu,
- Strategija stabilnosti prodaje.

Daljnja analiza pokazuje utjecaj svake pojedine strategije na poslovni rezultat.

1. Strategija troškovne fleksibilnosti, stabilizira proizvodnu cijenu, odnosno vinarija postaje troškovno konkurentnija na niskim troškovima, uz druge nepromijenjene varijable. Proizvodna cijena vina u ovoj strategiji ponovo je simulirana trokutnom razdiobom [=RiskTriang(10;11;12;RiskStatic(10))], ali rasponi su stabilniji (graf 15).


Rezultati primjene ove strategije daju sljedeće rezultate:



Graf 15: Prikaz kretanja neto dobiti uz primjenu strategije troškovne fleksibilnosti

Izvor: ispis iz @Risk

2. Strategija širenja na tržištu pretpostavlja povećanje prodaje, odnosno veće iskorištenje kapaciteta, uz sve druge varijable nepromijenjene. Prodaja se povećava i stabilizira i simulirana je primjenom trokutne razdiobe [=RiskTriang(150000;195000;210000)] (graf 16).




Graf 16: Prikaz kretanja ROA uz primjenu strategije širenja na tržištu

Izvor: ispis iz @Risk


3. Strategija stabilnosti prodaje polazi od pretpostavke kako utjecajem na cijenu vina, odnosno njenu stabilizaciju, vinarija dolazi u povoljniji financijski položaj. Pod utjecajem na cijenu vina pretpostavljamo mogućnosti ugovaranja proizvodnje, odnosno postojanje stabilnih veza i suradnje s određenim kupcima. U ovom slučaju, cijena je (prosječna) niža od cijene u baznom modelu, ali standardna devijacije je niža, odnosno cjenovni je rizik niži  $f=\text{RiskNormal}(18;1,5;\text{RiskStatic}(18))$  (graf 17).

U grafu 18 prikazano je kretanje Altman A-Z-score kod primjene strategija stabilnosti prodaje, širenja na tržištu i troškovne fleksibilnosti. Strategijom širenja na tržištu pokazalo se da je poduzeće najmanje sklono riziku od stečaja.



Graf 17: Prikaz kretanja ROE uz primjenu strategije stabilnosti prodaje

Izvor: ispis iz @Risk



Napomena: Plava je krivulja primjena strategije stabilnosti prodaje, zelena je krivulja širenja na tržištu, ljubičasta je krivulja troškovne fleksibilnosti.

Graf 18: Prikaz kretanja Altman A-Z-score uz primjenu strategija

Izvor: ispis iz @Risk



4. Strategija modernizacije i rasta kroz nova ulaganja polazi od pretpostavke novih zaduživanja vinarije, ali ona bi posljedično trebala dovesti do veće cijene.

Sve ranije prikazane strategije podrazumijevale su da vinarija ima unutarnje kapacitete za provedbu. U strategiji modernizacije i rasta kroz nova ulaganja polazimo od pretpostavke dodatnog zaduživanja koje bi vinariji trebalo dati snage za primjenu strategije troškovne fleksibilnosti, stabilnosti i širenja na tržištu. Cilj je na pokazatelju rasta vidjeti utjecaj odnosa zaduženosti i rasta. Isto tako, analizira se i financijski rizik kroz promjenu kamatne stope.

Dodatna ulaganja od 2.000.000 HRK koja ne bi bila praćena primjenom strateškog upravljanja rizikom dala bi sljedeće prosječne rezultate:

Tablica 55: Prikaz strategije modernizacije i rasta i usporedba s primjenom stohastičkog podmodela „Vinarije“

Opis	Minimum	Maximum	Srednja vrijednost	Standardna devijacija
Neto dobit	56.032,58	1.675.697,00	695.027,10	216.128,00
Neto dobit-G	-72.357,90	1.474.750,00	611.219,90	213.958,40
Bruto dobit	70.040,73	2.094.621,00	868.530,90	270.088,90
Bruto dobit-G	-90.447,30	1.843.437,00	763.585,80	267.363,80
EBIT	306.208,30	2.135.961,00	1.106.330,00	267.169,70
EBIT-G	255.423,80	2.237.155,00	1.103.026,00	265.660,80
ROA	0,01	0,19	0,10	0,03
ROA-G	-0,01	0,19	0,09	0,03
ROE	-0,02	0,38	0,17	0,04
ROE-G	-0,09	0,36	0,16	0,05
AAZS	1,30	3,01	2,11	0,24
AAZS-G	0,78	2,77	1,84	0,26

Napomena: Strategija rasta u modelu je označena s G (eng. growth, rast)

Izvor: ispis iz @Risk

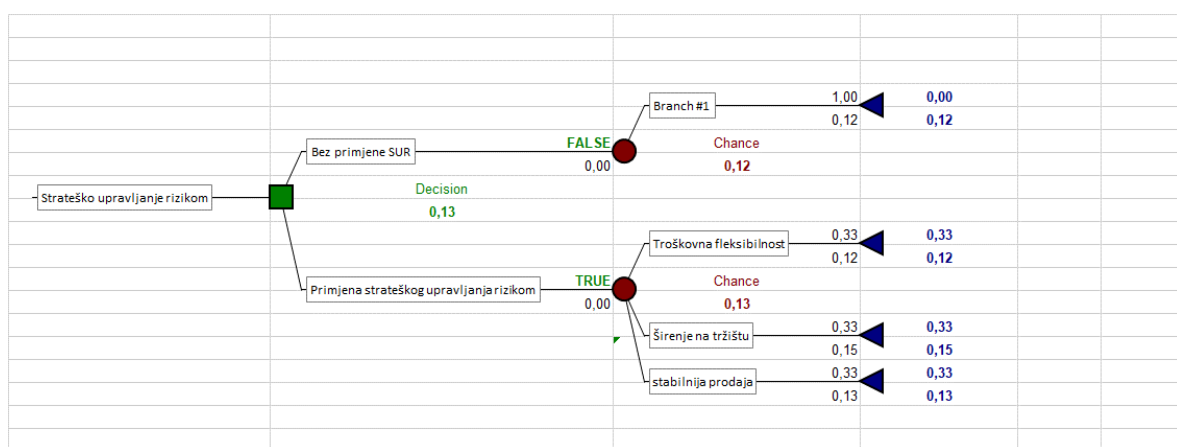
Dodatna ulaganja praćena primjenom strateškog upravljanja rizikom odrazila bi se na rast kompanije. Primjer učinka strateškog upravljanja rizikom vidljiv je u tablici 56. Primjena strategija rezultirala je povećanjem neto i bruto dobiti za 59%, EBIT-a za 41,35%, ROA za 36,06%, ROE za 22,56%, i Altman A-Z-score za 23,74%.

Tablica 56: Učinak strategije modernizacije i rasta na financijske pokazatelje

Opis	Minimum	Maximum	Srednja vrijednost	Standardna devijacija
Neto dobit	394.614,80	1.565.245,00	969.938,90	166.216,80
Bruto dobit	493.268,60	1.956.557,00	1.212.423,00	207.770,80
EBIT	820.451,50	2.327.331,00	1.551.844,00	207.347,10
ROA	0,06	0,18	0,13	0,02
ROE	0,10	0,28	0,20	0,03
AAZS	1,59	2,82	2,27	0,18

Izvor: ispis iz @Risk


Prikazom stabla odlučivanja vidljivo je da se primjenom strateškog upravljanja rizikom i širenjem na tržištu ostvaruje povećanje ROA na 0,15.




Slika 13: Stablo odlučivanja bez primjene i s primjenom strateškog upravljanja rizikom

Izvor: ispis iz @Risk


U grafičkom prikazu neto dobiti, EBIT-a i Altmanov A-Z-score vidljiv je pomak u „desno“ što je pozitivna promjena pokazatelja (graf 19, graf 20, graf 21).



Graf 19: Kretanje neto dobiti primjenom strategije modernizacije i rasta kroz nova ulaganja  
Izvor: ispis iz @Risk



Graf 20: Kretanje EBIT primjenom strategije modernizacije i rasta kroz nova ulaganja  
Izvor: ispis iz @Risk




Napomena: Crvena je krivulja primjena strategije upravljanja rizikom

Graf 21: Kretanje Altman A-Z-score-a primjenom strategije modernizacije i rasta kroz nova ulaganja

Izvor: ispis iz @Risk

Kod nastavka poslovanja jednakim načinom vjerojatnost stope rasta je u 3% slučajeva 0 ili negativna. Primjenom strategije modernizacije i rasta i dodatnim ulaganjem u 50% slučajeva moguća je stopa rasta od 12%. Bez primjene strategije, ali dodatnim ulaganjem, u 50% slučajeva moguća je stopa rasta od 7% (graf 22).



Napomena: Crvena je krivulja primjena strategije upravljanja rizikom

Graf 22: Kretanje stope rasta primjenom strategije modernizacije i rasta kroz nova ulaganja

Izvor: ispis iz @Risk

## 6. RASPRAVA

Vinogradarstvo i vinarstvo u Republici Hrvatskoj nije samo izvor dodatnih prihoda već predstavlja izvor materijalne egzistencije za male, srednje i velike poduzetnike i njihove obitelji. Rizici s kojima su vinari i vinogradari svakodnevno suočeni dodatno otežavaju nimalo lak posao u proizvodnji grožđa i vina.

Vinarije u Hrvatskoj danas djeluju kao dio globalnog tržišta.

Dostupni podaci govore o trendu smanjenja vinogradarskih površina (-3,04% u 2015./2005.) i proizvodnje vina (-1,29% u 2015./2005.) u svijetu koji nije zaobišao ni vinarije u Hrvatskoj. U 2015. godini u odnosu na 2005. vinogradarske površine u Hrvatskoj smanjene su za -13,76%, proizvodnja grožđa za -14,80% i proizvodnja vina za -20,51%.

Podaci pokazuju da je u Hrvatskoj zamjetan rast ukupnih količina vina iz uvoza (+120,14%), ali i pad vrijednosti vina (-19,39%) nakon pristupanja Hrvatske u EU. S druge strane zamjetno je povećanje broja poslovnih subjekata na tržištu vina domaće proizvodnje Republike Hrvatske, ali i smanjenje tržišnog udjela najznačajnijih vinarija. Tijekom 2011. godine u prometu vina sudjelovalo je 1.172 poslovnih subjekata, 33 vinarije ostvarile su 76,23% od ukupnog prometa vina domaće proizvodnje. U 2015. godini od 1.305 vinarija u prometu 33 vinarije ostvarile su 70,53% od ukupnog prometa vina (Hrvatski centar za poljoprivredu, hranu i selo, interni podaci, 2017). Prema kvaliteti vina za razdoblje od 2011. do 2015. povećao se udio kvalitetnih (sa 63,58% na 67,91%) i vrhunskih vina (s 5,09% na 6,47%) u odnosu na stolna vina (s 30,48% na 24,65%) u ukupnom prometu vina domaće proizvodnje, što ukazuje na povećanje ulaganja u tehnologiju i težnju prema višim cjenovnim segmentima u prodaji vina.

U istraživanju izazov je bio veliki broj izvora podataka s obzirom na metodologiju, vrijeme, svrhu i cilj prikupljanja podataka te stvaranja realne slike o sektoru vina. U području vinogradarstva i vinarstva podacima raspolažu Ministarstvo poljoprivrede, Hrvatski centar za poljoprivredu, hranu i selo, Agencija za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju, Hrvatska gospodarska komora, Državni zavod za statistiku i druge strukovne organizacije.

Pružanje kvalitetnih i pravodobnih informacija donosiocima odluka i u izvršnoj vlasti i kod poslovnih subjekata može pozitivno utjecati na stanje vinogradarsko-vinarskog sektora u Republici Hrvatskoj.

Naime, analiza COGEA S.R.L. (2014) kod procesa odlučivanja poslovnih subjekata naglašava potrebu o znanju razvoja tržišta i konkurentskog okruženja. Predlaže se razvoj

tržišnog sustava informiranja kako bi se europskim poslovnim subjektima u lancu nabave pružile informacije o promjenama na tržištu i u ponašanju konkurenata.

U sagledavanju stanja vinarija i vinarstva Hrvatske anketirani eksperti potvrđuju važnost turizma u plasmanu proizvoda (srednja vrijednost 4,20), vrhunske položaje (srednja vrijednost 4,12) i okolišne uvjete u proizvodnji grožđa i vina (srednja vrijednost 4,00) te za slabosti ističu usitnjenost površina, neorganiziranost vinogradara i nedostatak marketinga (srednja vrijednost 4,20).

Nove tehnologije (srednja vrijednost 2,00) i svi oblici turizma (agroturizam, vinski turizam, turistička potražnja) (srednja vrijednost 2,04) predstavljaju potencijal za vinarije u Hrvatskoj, koji je pod utjecajem rizika crnog tržišta i nedostatka inspekcije (srednja vrijednost 2,16) i konkurencije (ponude vina iste kvalitete, ali nižih cijena) (srednja vrijednost 2,20).

U istraživanju Tudisca i sur. (2013), vina Passito of Pantelleria i Moscato karakteristični su proizvodi koji njeguju ekonomiju otoka Pantelleria (Italija). Pokretanje lokalnog modela razvoja potrebno je za održavanje i razvoj lanca vrijednosti vina. Globalizacija tržišta otežava i ponekad sprečava mala i srednja poduzeća u ostvarenju konkurentne cijene na domaćem i inozemnom tržištu. Vinarije, da bi ostale konkurentne, usmjeravaju svoju pažnju na potrošače, visoku kvalitetu proizvoda i izvrstan omjer kvalitete i cijene. Na područjima gdje je masovna proizvodnja „karakterističan proizvod“ i gdje proizvodnja vina nije samo zasnovana na tradiciji već i na tehnologiji proizvodnje koja omogućava održavanje bio raznolikosti, vinogradarsko područje (teritorij) strateška je varijabla uspjeha poduzeća. Predlaže se da mala ili srednja poduzeća započnu aktivnosti zajedničkog marketinga s ciljem očuvanja sektora vina, održavanja zaposlenosti i konkurentnosti na tržištu.

Pregled literature i analiza stanja vinogradarstva i vinarstva u Hrvatskoj pokazuju da je pretpostavka o povećanju konkurencije istinita (povećanje svjetske trgovine vina za 76,88% u količinama i povećanje vrijednosti za 32,03% u 2015. u odnosu na 2005.) te će iz tog razloga u budućnosti strateško planiranje biti sve važnije.

## 6.1. Strateško upravljanje i rizici u vinarijama

U prepoznavanju rizika i strategija kod vinarija u Hrvatskoj anketirani proizvođači percipiraju relativno umjereno rizike s kojima se suočavaju. Posljedice nastanka rizika, 39,47% ispitanika smatra da prirodne nepogode mogu imati značajne posljedice na poslovanje tvrtke, 44,74% ispitanika smatra da biologija i okoliš mogu imati značajne posljedice, 47,37% ispitanika smatra da tržište može imati umjerenu posljedicu na poslovanje tvrtke, 50,00% ispitanika smatra da upravljanje i procesi imaju umjerenu posljedicu, dok za politički utjecaj (52,63%) smatraju da ima značajne posljedice na poslovanje.

U sljedećih pet godina anketirane vinarije smatraju za najveće prepreke u poslovanju prirodne nepogode (73,68%) i tržište (71,05%).

Ispitanici smatraju važnim primjenjivati strategije za upravljanje rizicima na gospodarstvu (poput pridržavanja tehnologije i agrotehničkih rokova, prodaje putem više različitih kanala, ...) i izvan gospodarstva (poput korištenja programa potpore) te strategije prijenosa rizika (osiguranje,...). S druge strane, ispitanici ponekad i često primjenjuju strategije izvan gospodarstva i ponekad primjenjuju strategije za upravljanje rizicima na gospodarstvu. Strategije prijenosa rizika rijetko se primjenjuju u anketiranim vinarijama u Hrvatskoj. Takvo promišljanje je očekivano ako se ima u vidu cijena primjene određenih strategija (cijena osiguranja, ulaganja koja su potrebna u tehnologiju, edukaciju,...).

Rezultati ankete sugeriraju da su ispitanici svjesni važnosti upravljanja rizicima, te neizravno potvrđuju hipotezu o vezi upravljanja rizicima, rasta i profitabilnosti vinarije. Ograničavajući čimbenik u ispunjavanju ankete veliki je broj ponuđenih odgovora. Istraživanje je nastojalo od ispitanika dobiti odgovore na što veći spektar rizika i strategija za upravljanje rizicima.

Rezultate provedene ankete potvrđuju i prethodna istraživanja. Gugić i sur. (2008) istraživali su izvore rizika i strategije upravljanja rizikom na vinogradarsko-vinarskim gospodarstvima Dalmacije. Među najviše ocijenjenim izvorima rizika bili su briga za zdravlje, klimatski utjecaji na proizvodnju i mogućnost plasmana proizvoda. Kao najvažnije strategije za upravljanje rizikom u vinogradarsko-vinarskoj proizvodnji ispitanici su odabrali korištenje vlastitog zemljišta, stalno učenje i informiranost te navodnjavanje.

Slični su rezultati Njavre i sur. (2005) u istraživanju izvora rizika i upravljanja rizicima za područje Slavonije i Baranje. Proizvođači najvišim ocjenama rizičnosti ocjenjuju zdravlje vlasnika i njegove obitelji, klimatske čimbenike (tuča, oluja, suša i sl.). Kada je riječ o važnosti strategija, po važnosti su izdvojene prikladna tehnologija, stalno učenje, proizvodnja na vlastitom poljoprivrednom zemljištu, radna snaga (dovoljan broj radnika i njihova kvaliteta).

## 6.2. Izloženost vinarija riziku

U razdoblju od 2005. do 2015. godine vinarije u Republici Hrvatskoj bile su izložene značajnim iskušenjima u svom poslovanju, od klimatskih uvjeta, „lošijih“ vinogradarskih godina (2015.), utjecaja gospodarske krize (od 2008. do 2017.), visokih cijena zaduženja (u 2009. kamatna stopa na kunske kredite bez valutne klauzule od 9,69%), rasta prosječne cijene utroška sirovine po jedinici mjere svih energenata u proizvodnji pića (prosječno 27,31%), promjena vezanih za cijene vina i sam postupak prometovanja vina, pristupanja Republike Hrvatske Europskoj uniji te „unosa“ i uvoza vina.

Problemi koji najviše muče male i srednje poduzetnike u EU-u odnose se na pronalazak kupaca, dostupnost obrazovane radne snage i menadžerskog kadra, konkurenciju te pristup financijskim sredstvima. U Hrvatskoj, među zaključcima izvještaja Europskog semestra za 2016. godinu o problemima čije rješavanje mora imati prioritet, naveden je nedostatak usklađenog i integriranog okvira politike za istraživanje i razvoj i nedostatak financiranja, visoke administrativne barijere, kompleksna i često promjenjiva regulativa te spora i neučinkovita državna administracija, slaba i rascjepkana javna uprava otežava isporuku usluga, prepreka dobivanja početnog kapitala. Razvoj hrvatskog gospodarstva, a time i sektora malih i srednjih poduzeća u budućem razdoblju ovisit će o odgovorima na identificirane izazove (Alpeza i sur., 2017).

Analiza poslovanja vinarija pokazala je da se od 2011. do 2015. godine broj poslovnih subjekata povećao za 20%, ali je 95 poslovnih subjekata imalo dostupne podatke u promatranom razdoblju. Prema veličini poslovnih subjekata, najveći broj subjekata su mali subjekti (91), a prema vrsti vlasništva, 76 poslovnih subjekata bilo je u privatnom vlasništvu. Rezultati financijskih pokazatelja sugeriraju da se većina vinarija za koje su postajali podaci u petogodišnjem razdoblju nalazi u nezavidnoj situaciji u svom poslovanju što se tiče likvidnosti, zaduženosti, ali i rizika od stečaja.

Prema ukupnoj prosječnoj vrijednosti za petogodišnje razdoblje, 47 poslovnih subjekata poslovalo je s dobitkom. Za usporedbu, ukupan prihod svih malih poduzeća u RH u 2015.



godini porastao je za 4,8%, srednjih poduzeća za 6%, a velikih poduzeća za 1,3% u odnosu na 2014. godinu (Alpeza i sur., 2017).

Od ukupno 95 poslovnih subjekata, prema pojedinim poslovnim subjektima 38 vinarija je imalo koeficijent tekuće likvidnosti veći od 2 prema ukupnoj prosječnoj vrijednosti. Prema srednjoj vrijednosti koeficijenta ubrzane likvidnosti tek je 29 poslovnih subjekata imalo prema prosječnoj vrijednosti koeficijent veći od 1. Kod koeficijenta financijske stabilnosti prema pojedinim poslovnim subjektima, 33 poslovna subjekta imala su srednju vrijednost veću od 1 te se može zaključiti da pripadaju financijski nestabilnim poduzećima. Za cijelo promatrano razdoblje, 67 subjekata imalo je srednju vrijednost razine zaduženosti veću od 0,49.

Prema ROA indikatoru, većina poslovnih subjekata ima visoki stupanj intenzivnosti imovine. ROE indikator iskazuje ekstremne vrijednosti, vrlo visoke (118%), ali i vrlo male vrijednosti (-314,31%). Uzimajući u obzir odnos ROA i ROE te koeficijente ROE koji su značajno iznad vrijednosti ROA, može se zaključiti da bi se poslovnim subjektima isplatilo koristiti tuđim kapitalom, i obrnuto.

Prema poslovnim subjektima, prosječnu vrijednost ROA manju od 5% imala su 84 subjekta. Nije bilo poslovnih subjekata koji su imali vrijednost ROA veću od 20%. Prosječna vrijednost ROE za cijelo razdoblje kretala se od -314,31% do 118,04%.

Ukupna prosječna vrijednost Altmanov A-Z-score modela za 16 poslovnih subjekata za cijelo razdoblje bila je veća od 2,9, a 63 poslovna subjekta imala su vrijednost jednaku ili manju od 1,23. Jedan poslovni subjekt nije uključen u analizu jer je predstavljao *outlier*.

Financijska analiza 95 poduzeća pokazala je da su mali poslovni subjekti likvidniji, manje zaduženi od velikih odnosno srednje velikih. Postoji „problem“ niske profitabilnosti srednje velikih poduzeća (ROA se kreće od -0,24 u 2011. do -0,15 u 2015., ROE se kreće od 0,15 u 2011. do 0,01 u 2015.) te velikim i malim poduzećima prijeti vrlo veliki rizik stečaja. Prema pravnom obliku, dionička društva bilježe najniže srednje vrijednosti koeficijenta tekuće likvidnosti, ubrzane likvidnosti, financijske stabilnosti, najvišu razinu zaduženosti i najnižu vrijednost ROE. Srednje velika poduzeća imala su najnižu vrijednost Altmanov A-Z-score modela, dok su poljoprivredne zadruge imale najvišu vrijednost, od 2,07 pokazatelja A-Z-score-a.

Za usporedbu, rezultati rada Novotná i Svoboda (2014) pokazali su da prosječno gospodarstvo u Češkoj ostvaruje prosječni profit od 3,2 mil. CZK od 2004. do 2010. (osim u 2009.). Profitabilnost se promatra u pozitivnom vrijednostima, ali prosječna vrijednost ne

prelazi 4%. Općenito, likvidnost je imala pozitivne vrijednosti. Ukupan dug nije bio veći od 50%. Najbolji su rezultati pokazatelja bili kod tvrtki ograničene odgovornosti.

Deloitte i vinari Novog Zelanda (2016) pripremili su *benchmarking* industrije vina za 2015. godinu u kojoj je uključen i *benchmarking* financijskih pokazatelja. Vinarije su podijeljene prema godišnjem ukupnom prihodu. Tekuća likvidnost izračunana je kao trenutna imovina podijeljena s trenutnim obvezama. Ako je tekuća likvidnost veća od 200% (2\$ imovine za svaki 1\$ trenutnih obveza) tada se smatra da tvrtka ima dobru kratkotrajnu financijsku likvidnost (ovisno o odnosu trenutne imovine na zaliham). Zabilježena je tekuća likvidnost, uključujući zalihe, koja je značajno iznad 200%.

Glavni cilj istraživanja Totha (2014) mjerenje je sistematskog rizika poljoprivrednih poduzeća u Slovačkoj koja nisu na burzi, mjerenjem varijabilnosti ROE tijekom 2009. - 2012. Rezultati su pokazali da je prosječni povrat (mjeren kao ROE) u poljoprivredi Slovačke tijekom perioda bio 0,048%, što ukazuje da je profitabilnost cijelog sektora niska. U slučaju normalne distribucije povrata u portfoliju, izračunani rizik (3,000%) može se interpretirati kao interval pouzdanosti, gdje je postignut povrat između -2,952% do 3,048% s razinom pouzdanosti od 68,3%. Prema teoriji, ukupni rizik portfolija smanjuje se povećanjem broja poduzeća u portfoliju. Ipak, nakon podjele skupa podataka na zadruge i poduzeća, u slučaju zadruga rizik je veći od izračunanog sistematskog rizika, s druge strane, rizik poduzeća je niži.

*Benchmarking* horizontalne analize financijskih pokazatelja vinarija obrađivali su Jordan i sur. (2010) u Kaliforniji, Oregonu i Washingtonu SAD-a za 2007. i 2008. godinu. ROA je relativno nizak i varira od približno 4% do 10% tijekom promatranog razdoblja. U industriji vina, smanjenje troškova prodane robe neće se primijetiti u računu dobiti i gubitka kroz nekoliko fiskalnih perioda jer se radi o ciklusima dugotrajnih zaliha.

Rezultati rada Montezemola (2006) pokazali su da su veća poduzeća učinkovitija, s obzirom na profitabilnost, rast i financijske kapacitete, od srednjih i malih poduzeća. Provedena su dva istraživanja, poduzeća na burzi i najvažnijih talijanskih vinarija. Više nego studija vinarija koje su na burzi, studija talijanskih vinarija pokazala je da veličina poslovanja i poslovni model postaju sve važniji u tumačenju konkurentnosti i financijskih pokazatelja u industriji vina.

S obzirom na broj poljoprivrednih gospodarstava koja su uključena u vinogradarsko-vinarsku proizvodnju ograničavajući čimbenik za njihovo pozornije promatranje predstavlja nedostupnost financijskih podataka putem FINA-e. Naime, Zakonom o računovodstvu („Narodne novine“, br. 109/07, 54/13), među ostalim, definirani su i obveznici te obveza predaje financijskih izvještaja obveznika prema FINA-i. Dodatni ograničavajući čimbenik bila je i činjenica da poslovni subjekti u NKD-u navode više djelatnosti te prema Nacionalnoj klasifikaciji djelatnosti 2007. (NKD 2007.) registriranoj proizvodnji vina od grožđa, u analizu nisu uključene pojedine značajne vinarije.

Rezultati modela višestruke regresije na analizi vinarija ( $n = 95$ ), ukupnog prihoda (zavisne varijable) i broja zaposlenih, materijalnih troškova, troškova osoblja (nezavisne varijable) pokazali su da *dummy* varijable „županija“ i „domaći kapital“ nisu statistički značajne. Varijable „pravni status“ i „veličina vinarije“ statistički su značajne u modelu. Nakon procjene i analize modela višestruke regresije slijedila je regresijska analiza ukupnog prihoda (zavisna varijabla) i po jedne nezavisne varijable i jedne *dummy* varijable. „Pravni status“ i „veličina“ statistički su značajne varijable. „Županija“ i „domaći kapital“ nisu statistički značajne. Svi testovi značajnosti nezavisnih varijabli provedeni su uz standardnu razinu signifikantnosti testa 5%.

Na kraju je regresiran ukupni prihod (zavisna varijabla) i sve nezavisne varijable svaka posebno, bez *dummy* varijabli u modelima jednostavne linearne regresije sa standardiziranim vrijednostima varijabli. Materijalni trošak potvrđen je kao najrizičnija varijabla koja utječe na ukupan prihod.

Rezultati istraživanja Sellers i Sottini (2016) na uzorku od 723 talijanske vinarije (društva ograničene odgovornosti i zadruga) u 2013. pokazali su da veličina ima pozitivan utjecaj na ekonomski učinak vinarija, što su pokazali i rezultati regresijske analize provedene u ovom doktorskom radu. Menadžeri bi trebali biti svjesni važnosti praćenja vlastitog učinka kako bi se osigurala konkurentnost njihovih vinarija.

Istraživanje Delord i sur. (2015) dovodi u pitanje izvješće Europskog parlamenta koje pokazuje pozitivnu korelaciju veličine i efikasnosti bez uzimanja u obzir široki raspon cijena vina. Članak Delord i sur. (2015) pokazuje da u Francuskoj od 2005. do 2007. veličina gospodarstva ima mali utjecaj na učinak. Uočene značajne razlike rezultat su razlika u prodajnoj cijeni vina.

Rezultati studije Kobzar (2006) pokazali su da su gospodarstva s većom solventnošću imala viši koeficijent varijacije prihoda dok su gospodarstva s relativno većim obvezama prema kreditorima imala niži koeficijent varijacije prihoda. Visoki varijabilni troškovi povezani su s većom varijabilnošću prihoda gospodarstva. Vezano za vrstu gospodarstva, obiteljska gospodarstva imala su stabilnije prihode od partnerstava ili gospodarstava s upraviteljima. Analiza između gospodarstava pokazala je da poslovne i financijske strukturne varijable imaju utjecaj na varijabilnost prihoda. Zemljopisna lokacija, dob poljoprivrednika, obrazovanje, varijabilni troškovi, koeficijent financijske poluge, prihodi izvan gospodarstva i poljoprivredna površina imaju značajan utjecaj na varijabilnost prihoda gospodarstva.

### 6.3. Rangiranje vinarija prema stupnju rizika

Pretpostavka o rangiranju vinarija na visoko, srednje i niskorizične je potvrđena. Rezultati su pokazali veliki broj visoko rizičnih subjekata. Od 95 promatranih vinarija, visoko rizične vinarije, njih 75, bile su većinom s područja primorske Hrvatske, s manje od 10 zaposlenih, s udjelom 100% domaćeg kapitala, privatnog vlasništva od osnivanja, pripadaju u skupinu malih poduzeća, društva ograničene odgovornosti.

### 6.4. Strateško upravljanje rizikom

U usporedbi s rezultatima provedene ankete „Strateško upravljanje rizikom vinarija u Hrvatskoj“, i izdvojene strategije koje se primjenjuju na i izvan poljoprivrednih gospodarstava te strategije prijenosa rizika, razvijen je model strateškog upravljanja rizikom vinarije primjenom strategije troškovne fleksibilnosti, strategije širenja na tržištu, strategije stabilnosti prodaje i strategije modernizacije i rasta kroz nova ulaganja. Najbolji rezultati neto i bruto dobiti, EBIT, ROA, ROE, Altman A-Z-score pokazali su se kod strategije modernizacije i rasta kroz nova ulaganja. Rezultati modela odnosno strategije modernizacije i rasta kroz nova ulaganja rezultirali su povećanjem stope rasta, Altman A-Z-score-a, neto i bruto dobiti, dobiti prije kamata i poreza, povrata na imovinu, povrata na kapital za 7%, 23,74%, 59%, 41,35%, 36,06% i 22,56%.

U znanstvenoj zajednici, modele upravljanja rizikom poljoprivrednih gospodarstava i poduzetničke modele rizika istražuju Lien i Hardaker (2001) te Bewley i sur. (2010). Modeli upravljanja rizikom na području vinarstva su rijetki (Reynolds i sur., 2006; Köprülü, 2014).

Higgins (2014) u svom projektu razvija stohastički simulacijski model za male i srednje vinarije u SAD-u. U razvoju modela korištene su kontrolne, fiksne i stohastičke varijable. Kontrolne su varijable razvijene kako bi se prilagodili veličina vinarije i obujam poslovanja prema kojima je osnovni model pripremljen. Primjeri kontrolnih varijabli su veličina djelatnosti, trenutna veličina „kluba“ vina, cijene vina, izvor voća i sorte. Fiksne varijable korištene su za „nekritične“ ekonomske varijable, dok su stohastičke varijable korištene za nekontrolirane ekonomske varijable (uključujući cijene voća, vjerojatnost gubitka, proizvodna ograničenja). Stohastičke varijable korištene su za izračun rizika i nesigurnosti cijena, i za predviđanje proizvodnje.

Cilj studije Asci i sur. (2014) je istraživanje investicijskog potencijala proizvođača rajčice u staklenicima, u Floridi. Tehnologija proizvodnje rajčica u staklenicima smatra se strategijom transfera utjecaja na profitabilnost proizvođača Floride zbog povećanog uvoza rajčice iz Meksika. NPV analiza sugerira da je ulaganje u visoko tehnološke staklenike bolje od „uobičajene“ proizvodnje u staklenicima i na otvorenom prostoru.

Rezultati rada Newton i sur. (2015) pokazali su da odluka o distribuciji vina izravno do potrošača utječe na rast vinarije. Istraživanje je provedeno na 71 vinariji (malima i srednje velikima) u SAD-u. Ispitivan je utjecaj strategija diferencijacije na profitabilnost i rast. Rezultati ovog istraživanja pokazuju da izbor distribucijskog kanala izravne prodaje pozitivno utječe na *gross profit margin* i stope rasta vinarije. Izbor opskrbnog lanca koji nabavlja grožđe također pozitivno utječe na *gross profit margin*.

Statistički su modeli pomoć pri odlučivanju, ali nikako ne mogu zamijeniti iskustvo i procjenu menadžera rizika pri donošenju odluka kako upravljati rizicima kojima je poslovanje poduzeća izloženo (Miloš Sprčić i Radić, 2011).

## 7. ZAKLJUČCI

Cilj rada bio je ocijeniti stanje sektora i uvjete poslovanja vinarija, analizirati rizike s kojima se vinarije suočavaju i upravljanje rizikom koje primjenjuju. Na temelju postojećeg stanja i izračuna ključnih pokazatelja poslovanja kreiran je model strateškog upravljanja rizikom u kojemu su testirane strategije upravljanja rizikom i njihov utjecaj na poslovanje.

o Cilj istraživanja o ocjeni stanja sektora i uvjeta poslovanja vinarija je ispunjen. Turizam (srednja vrijednost 4,20) i vrhunski položaji (srednja vrijednost 4,12) najvažnije su prednosti vinarija i vinarskog sektora, a male usitnjene površine, neorganiziranost vinogradara i nedostatak marketinga vina (srednja vrijednost 4,20) najveće slabosti sektora prema anketi stručnjaka. Kao prilike stručnjaci smatraju nove tehnologije (srednja vrijednost 2,00), razvoj agro-turizma i vinskog turizma (srednja vrijednost 2,04) i porast turističke potražnje (srednja vrijednost 2,16), a crno tržište, nedostatak nadzora nad (nelojalnom) konkurencijom (srednja vrijednost 2,16), ponudu jeftinijih i kvalitetom usporedivih vina (srednja vrijednost 2,20), neplaćanje i nelikvidnost (srednja vrijednost 2,28) za najvažnije prijetnje.

o Cilj istraživanja analize rizika u poslovanju vinarija je ispunjen. Anketno ispitivanje pokazalo je da vinarije u Hrvatskoj prepoznaju rizike i strategije, ali nedovoljno primjenjuju strategije upravljanja rizicima. Značajna je vjerojatnost nastupanja tržišnih rizika, a 52,63% ispitanika smatra da politika i institucije imaju značajne posljedice na poslovanje. Ispitanici koriste nacionalne i EU programe potpore, diversifikaciju te primjenjuju strategije poput pridržavanja tehnologije i agrotehničkih rokova, korištenja vlastitog zemljišta, prodaje proizvoda putem više različitih kanala, stalnog učenja i informiranosti, upravljanje ljudskim potencijalom i sustava nabave i logistike. Strategije prijenosa rizika (osiguranje, prodajni ugovori, ugovori s kooperantima, proizvodnja za poznatog kupca) rijetko se primjenjuju u anketiranim vinarijama u Hrvatskoj. Prema bodovnoj ljestvici rizika (*risk scorecard*), za nastanak grupe rizika prirodnih nepogoda i politike i institucija mogu se očekivati značajne posljedice. Isto tako, prema pojedinačnim rizicima, za nastanak rizika skupe i složene državne administracija mogu se očekivati značajne posljedice.

o Cilj istraživanja rangiranja vinarija prema stupnju rizika i djelomično je potvrđena hipoteza istraživanja da se vinarije značajno razlikuju u izloženosti riziku.

Rezultati financijske analize pokazali su da su mali poslovni subjekti likvidniji, manje zaduženi od velikih odnosno srednje velikih. Postoji „problem“ niske profitabilnosti kod srednje velikih poduzeća. U većini promatranih poduzeća prijeti vrlo veliki rizik stečaja mjeren Altmanovim A-Z-score-om. Prema pravnom obliku dionička društva bilježe najniže srednje vrijednosti koeficijenta tekuće likvidnosti, ubrzane likvidnosti, financijske stabilnosti, najvišu razinu zaduženosti i najnižu vrijednost povrata na kapital. Dionička društva imala su srednju vrijednost Altman A-Z-score modela od -1,99, dok su poljoprivredne zadruge imale srednju vrijednost pokazatelja A-Z-score-a od 2,07. Rezultati jednostavne linearne regresije pokazali su da materijalni troškovi (standardizirani koeficijent 0,94) imaju najveći relativni utjecaj na ukupan prihod. Prema standardnoj devijaciji Altmanov-og A-Z-score rangirano je 95 vinarija u Hrvatskoj. Za razdoblje od 2011. do 2015. godine bilo je 8 poslovnih subjekata kojima prijeti vrlo mali rizik od stečaja, 10 srednje rizičnih vinarija i 75 visoko rizičnih vinarija, što djelomično potvrđuje hipotezu o postojanju razlika između vinarija s obzirom na stupanj financijskog rizika.

o Istraživanjem je potvrđena hipoteza da primjena strateškog upravljanja rizikom doprinosi rastu i profitabilnosti vinarija. Instrumenti upravljanja rizikom uključeni su u izradu modela te je ustanovljena učinkovitost strateškog upravljanja rizikom primjenom stohastičkih simulacija u scenarije poslovnog razvoja na primjeru modela.

Poslovanje je simulirano na statičkoj i stohastičkoj varijanti na primjeru hipotetske vinarije. Na bazni stohastički podmodel i scenarij modernizacije i rasta kroz nova ulaganja razvijene su strategije: strategija troškovne fleksibilnosti koja stabilizira proizvodnu cijenu vina, strategija širenja na tržištu koja pretpostavlja povećanje prodaje, odnosno veće iskorištenje kapaciteta, strategija stabilnosti prodaje koja polazi od pretpostavke kako utjecajem na cijenu vina, odnosno njenu stabilizaciju, vinarija dolazi u povoljniji financijski položaj. Scenarij modernizacije i rasta kroz nova ulaganja polazi od pretpostavke novih zaduživanja vinarije. Rezultati modela odnosno strategije modernizacije i rasta kroz nova ulaganja i primjena strateškog upravljanja rizikom rezultirali su povećanjem stope rasta, Altman A-Z-score-a, neto i bruto dobiti, dobiti prije kamata i poreza, povrata na imovinu, povrata na kapital za 7%, 23,74%, 59%, 41,35%, 36,06% i 22,56%.

Ovaj doktorski rad može pridonijeti razumijevanju strateškog upravljanja i upravljanja rizikom u poljoprivredi. Unutar vinarskog sektora rad može poslužiti poduzećima za sagledavanje i upravljanje rizicima, a državnoj administraciji u kreiranju pojedinih sektorskih politika. S obzirom na relativno mali broj istraživanja rizika i strategija za upravljanje rizicima u poljoprivredi, postoji prostor za daljnja istraživanja rizika i strategija za upravljanje rizicima neovisno o poljoprivrednom sektoru, a ovaj doktorski rad može poslužiti kao obrazac.



## 8. POPIS LITERATURE

1. Anderson, J. R. (2001). Risk Management in Rural Development: A Review. Rural Development Strategy Background Paper 7, Rural Development Department, The World Bank, Washington, D. C. iz The World Bank (2005). Managing Agricultural Production Risk, Innovations in Developing Countries, report no. 32727-GLB, Washington DC, SAD.
2. Asfaw, S., Lipper, L., (Food and Agriculture Organization of the United Nations) (2016). Managing climate risk using climate-smart agriculture. Dostupno na: <http://www.fao.org/3/a-i5402e.pdf>. Pristupljeno 21. 01. 2017.
3. Asci, S., VanSickle, J. J., Cantliffe, D. J. (2014). Risk in Investment Decision Making and Greenhouse Tomato Production Expansion in Florida. International Food and Agribusiness Management Review 17(4): 1-26.
4. Agencija za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju (2016). Vinogradarski registar. Dostupno na: <http://www.apprrr.hr/vinogradarski-registar-1128.aspx>. Pristupljeno 08. 05. 2017.
5. Aimin, H. (2010). Uncertainty, Risk Aversion and Risk Management in Agriculture. U International Conference on Agricultural Risk and Food Security. Agriculture and Agricultural Science Procedia 1: 152-156.
6. Alpeza, M., Has, M., Novosel, M., Singer, S. (2017). Izvešće o malim i srednjim poduzećima u Hrvatskoj – 2016. uključujući rezultate GEM – Global Entrepreneurship Monitor istraživanja za Hrvatsku za 2015. godinu. Centar za politiku razvoja malih i srednjih poduzeća i poduzetništva. Dostupno na: [www.cepor.hr/wp-content/uploads/2015/04/Cepor-izvjesce-2016-HR-web.pdf](http://www.cepor.hr/wp-content/uploads/2015/04/Cepor-izvjesce-2016-HR-web.pdf). Pristupljeno 26. 09. 2017.
7. Bahovec, V., Erjavec N. (2015). Statistika. II izdanje. Element. Zagreb.
8. Barry, P. J., Ellinger, P. N., Baker, C. B., Hopkin, J. A. (2000). Financial Management in Agriculture. Sixth Edition. Interstate Publishers, Inc.
9. Benni, N. El., Finger, R. (2013). Gross revenue risk in Swiss dairy farming. Journal of Dairy Science 96(2): 936-948.
10. Bewley, J. M., Boehlje, M. D., Gray, A. W., Hogeveen, H., Kenyon, S. J., Eicher, S. D., Schutz, M. M. (2010). Stochastic simulation using @Risk for dairy business investment decisions. Agricultural Finance Review 70(1): 97-125.
11. Bendeković, J. (1991). Procjena ekonomske vrijednosti poduzeća. Ekonomski pregled 42(6-7): 287-328. iz Aralica, Z. (2005). Povezanost vrijednosti kapitala i odabranih pokazatelja u proizvodnim poduzećima. Ekonomski pregled 56(12): 1190-1216.
12. Bolfek, B., Stanić, M. (2011). Struktura bilance kao pokazatelj lošeg poslovanja. Oeconomica Jadertina 1: 76-87.

13. Božikov, J. (2007). Modeliranje i simulacija. Dostupno na: [https://www.researchgate.net/publication/265450294\\_Modeliranje\\_i\\_simulacija](https://www.researchgate.net/publication/265450294_Modeliranje_i_simulacija).  
Pristupljeno 17. 10. 2017.
14. Brigham, E. F., Ehrhardt, C. M. (2011, 2009). Financial Management Theory and Practice. South Western a part of Cengage Learning: 914-916. Dostupno na: [http://www.google.hr/books?hl=hr&lr=&id=fJ9dj4kCo0AC&oi=fnd&pg=PR6&dq=financial+management+methods&ots=SiUGK1o1g3&sig=XrDf4YSGeBD\\_rAgV6dc2AmH8Up8&redir\\_esc=y#v=snippet&q=speculative&f=false](http://www.google.hr/books?hl=hr&lr=&id=fJ9dj4kCo0AC&oi=fnd&pg=PR6&dq=financial+management+methods&ots=SiUGK1o1g3&sig=XrDf4YSGeBD_rAgV6dc2AmH8Up8&redir_esc=y#v=snippet&q=speculative&f=false).  
Pristupljeno 08. 05. 2017.
15. Buble, M. (2000). Management, Ekonomski fakultet, Split.
16. Buble, M. (2000). Management, Ekonomski fakultet, Split iz Šarlija, N., Penavin, S., Harc, M. (2009). Predviđanje nelikvidnosti poduzeća u Hrvatskoj. Zbornik Ekonomskog fakulteta u Zagrebu 7(2): 21-36.
17. Budin, T. (1981). Donošenje ekonomski racionalnih odluka u uvjetima neizvjesnosti i rizika od vremenskih prilika. Doktorska disertacija. Agronomski fakultet Sveučilišta u Zagrebu.
18. Butigan, R. (2010). Utjecaj marketinških mreža na uspješnost poslovanja malih i srednjih poduzeća. Doktorska disertacija. Ekonomski fakultet Sveučilišta u Zagrebu.
19. Chandler, A. D. (1963). Strategy and Structure, Cambridge (Te MIT Press) iz Buble, M. (2000). Management, Ekonomski fakultet, Split.
20. Charters, S., Clark-Murphy, M., Davis, N., Brown, A., Walker, E. (2008). An exploration of managerial expertise in the Western Australian wine industry. International Journal of Wine Business Research 20.2: 138-152.
21. COGEA S.R.L. (2014). The European Commission. Study on the competitiveness of European wines final report. Dostupno na: [https://ec.europa.eu/agriculture/sites/agriculture/files/external-studies/2014/eu-wines/fulltext\\_en.pdf](https://ec.europa.eu/agriculture/sites/agriculture/files/external-studies/2014/eu-wines/fulltext_en.pdf).  
Pristupljeno 26. 01. 2017.
22. Cohen, J. W. (1988). Statistical power analysis for the behavioral sciences (2nd edn) iz Hillsdale, NJ: Lawrence Erlbaum Associates iz Pallant, J. (2005). SPSS survival manual: a step by step guide to data analysis using SPSS. Crows NEst NSW (Sydney): Allen & Unwin.
23. Cornell University Library (2017). Dostupno na: <http://guides.library.cornell.edu/HADM2720/SWOT>.  
Pristupljeno 23. 09. 2017.
24. Čižmešija, M. (2016, a). Regresijska analiza. Dostupno na: [web.efzg.hr/dok/STA/mcizmesija/4.%20Jednostavna%20linearna%20regresija.pdf](http://web.efzg.hr/dok/STA/mcizmesija/4.%20Jednostavna%20linearna%20regresija.pdf).  
Pristupljeno: 03. 11. 2017.

25. Čižmešija, M. (2016, b). Model višestruke linearne regresije. Dostupno na: [web.efzg.hr/dok/STA/mcizmesija/5.%20Višestruka%20linearna%20regresija.pdf](http://web.efzg.hr/dok/STA/mcizmesija/5.%20Višestruka%20linearna%20regresija.pdf).  
Pristupljeno: 03. 11. 2017.
26. Čižmešija, M. (2017). Regresija, vinarije. Email.
27. David, F. R. (2011). Strategic Management Concepts and Cases, XIII izdanje, Pearson Prentice Hall.
28. Decision Trees Primer (2007). Decision Trees A Primer for Decision -making Professionals. Dostupno na: [http://www.stylusandslate.com/decision\\_trees/4\\_0\\_glossary/4\\_0\\_glossary.html](http://www.stylusandslate.com/decision_trees/4_0_glossary/4_0_glossary.html).  
Pristupljeno 22. 06. 2017.
29. Declerck, F. (2005). Typology and financial performance of Champagne makers according to distribution. International Food and Agribusiness Management Review 8(4): 1-22.
30. Deighton, J., Dessain, V., Pitt, L., Beyersdorfer, D., Sjoman, A. (2007). Marketing Chateau Margaux. Harvard Business School: 9-507-033.
31. Deković, Ž., Žaja, J., Smiljčić, I. (2017). Rizik i financijski menadžment. Zbornik radova Veleučilišta u Šibeniku 1-2: 123-139.
32. Deloitte, New Zealand Winegrowers (2016). New Zealand wine industry benchmarking survey. Dostupno na: <https://www2.deloitte.com/content/dam/Deloitte/nz/Documents/wine/nz-en-Vintage-2015-wine-survey.pdf>.  
Pristupljeno 18. 04. 2017.
33. Delord, B., Montaigne, E., Coelho, A. (2015). Vine planting rights, farm size, and economic performance: Do economies of scale matter in French viticulture sector?. Wine Economics and Policy 4: 22-34.
34. Dercon, S. (2000). Income risk, coping strategies and safety nets. Background paper World Development Report 2000/01. Centre for the Study of African Economies Oxford University Department of Economics.
35. DeVellis, R. F. (1991). Scale development. Newbury Park, NJ: Sage Publications iz Kovačić, D., Markovina, J., Čondrić, A. (2013). Testiranje pouzdanosti upitnika prehrambenog životnog stila. U 48. hrvatski i 8. međunarodni simpozij agronoma, Dubrovnik: Poljoprivredni fakultet Sveučilište Josipa Jurja Strossmayera u Osijeku: 176-179.
36. Dorfman, J. H., Karali, B. (2008). Do Farmers Hedge Optimally or by Habit? A Bayesian Partial-Adjustment Model of Farmer Hedging. U Conference on Applied Commodity Price Analysis, Forecasting, and Market Risk Management. St. Louis, MO. Dostupno na: <http://ageconsearch.umn.edu/bitstream/37596/2/confp02-08.pdf>.  
Pristupljeno 08. 05. 2017.

37. Državni zavod za statistiku Republike Hrvatske (2005 - 2015). Statistički ljetopis Republike Hrvatske. Baze podataka. Zagreb: Državni zavod za statistiku. Dostupno na: [www.dzs.hr](http://www.dzs.hr). Pristupljeno 2014., 2015., 2016., 2017.
38. Državni zavod za statistiku Republike Hrvatske (2017, a). Sumarna tabela prema NKD-u po energentima - repro. Leljak, I. Email.
39. Državni zavod za statistiku Republike Hrvatske (2017, b). Sumarna tabela o utrošku sirovina i mat.l\_2015. Leljak, I. Email.
40. Državni zavod za statistiku Republike Hrvatske (2017, c). Upit, sumarna tabela prema NKD-u po energentima - repro. Leljak, I. Email.
41. Državni zavod za statistiku Republike Hrvatske (2015). Upit, cijene inputa i outputa. Leljak, I. Email.
42. Duquesnois, F., Călin, G., Le Roy, F. (2010). Wine producers' strategic response to a crisis situation. *International Journal of Wine Business Research* 22.3: 251-268.
43. Enjolras, F., Capitanio, F., Aubert, M., Adinolfi, F. (2014). Direct payments, crop insurance and the volatility of farm income: some evidence in France and in Italy. *New Medit* 13(1): 31-40.
44. Eurostat (2016, a). Wine balance sheet. Dostupno na: [http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=apro\\_cpb\\_wine&lang=en](http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=apro_cpb_wine&lang=en). Pristupljeno 09. 09. 2016.
45. Eurostat (2017, b). Annual detailed enterprise statistics for industry (NACE Rev. 2, B-E) [sbs\_na\_ind\_r2]. Dostupno na: [http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=sbs\\_na\\_ind\\_r2&lang=en](http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=sbs_na_ind_r2&lang=en). Pristupljeno 24. 10. 2017.
46. FINA (2016). Isporuka podataka. Email.
47. Gašparec-Skočić, Lj., Mihaljević, B. (2005). Vinogradarstvo na pragu ulaska u EU. U 40. znanstveni skup agronoma s međunarodnim sudjelovanjem, Opatija: Poljoprivredni fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku.
48. Grgić, I., Kovačić, D., Bedek, Ž. (2010). Liberalizacija hrvatskog tržišta vina - izazov i/ili prijetnja. U 45. hrvatski i 5. međunarodni simpozij agronoma, Opatija: Poljoprivredni fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku: 239-243.
49. Gugić, J., Par, V., Njavro, M., Verović, A. (2008). Izvori rizika i strategije upravljanja rizikom na vinogradarsko vinarskim gospodarstvima u Dalmaciji. *Agronomski glasnik* 70: 425-438.
50. Hair, J. F. J., Anderson, R. E., Tatham, R. L., Black, W. C. (1998). *Multivariate Data Analysis*, Prentice Hall, New Jersey iz Butigan, R. (2010). Utjecaj marketinških mreža na uspješnost poslovanja malih i srednjih poduzeća. Doktorska disertacija. Ekonomski fakultet Sveučilišta u Zagrebu.

51. Hajenić, M., Ivanković, A. (2014). Analiza menadžmenta uzgoja hrvatskog posavca. *Stočarstvo* 67(4): 127-136.
52. Han, J., Omta, S. W. F., Trienekens, J. H. (2007). The joint impact of supply chain integration and quality management on the performance of pork processing firms in China. *Conference Paper. International Food and Agribusiness Management Review* 10(2): 67-95.
53. Hardaker, J. B., Huirne, R. B. M., Anderson, J. R., Lien, G. (2002). *Coping with Risk in Agriculture*, second edition, CABI publishing, Wallingford, Velika Britanija.
54. Heyder, M., Theuvsen, L., Davier, Z. V. (2010). Strategies for coping with uncertainty: The adaptation of food chains to volatile markets. *Journal on Chain and Network Science* 10 (1): 17-25.
55. Higgins, L. (2014). Economic Stochastic Simulation Model for Small to Medium Sized Wineries. U American Association of Wine Economists annual meeting in Walla Walla, Washington. Dostupno na: <http://www.wine-economics.org/aawe/wp-content/uploads/2014/06/64-WW-2014-Higgins.pdf>. Pristupljeno 18. 04. 2017.
56. Hrvatska narodna banka (2016, a). ESA 1995/BPM5. Dostupno na: <http://www.hnb.hr/statistika/statisticki-podaci/arhiva/esa-1995-bpm5>. Pristupljeno 29. 08. 2016.
57. Hrvatska narodna banka (2016, b). ESA 1995/BPM5. Dostupno na: <http://www.hnb.hr/statistika/statisticki-podaci/arhiva/stara-nacionalna-metodologija>. Pristupljeno 29. 08. 2016.
58. Hrvatski centar za poljoprivredu, hranu i selo (2017, a). Izvješće o radu HCPHS. Dostupno na: <http://www.hcphs.hr/godisnja-izvjesca-planovi-rada/>. Pristupljeno 20. 04. 2017.
59. Hrvatski centar za poljoprivredu, hranu i selo (2017, b). Interni podaci.
60. Hrvatski centar za poljoprivredu, hranu i selo (2017, c). Popis propisa iz područja vinogradarstva i vinarstva. Dostupno na: <http://www.hcphs.hr/zvv/propisi/>. Pristupljeno 26. 05. 2017.
61. Hrvatski sabor (2014). Zakon o faktoringu. Zagreb: Narodne novine 94/14, 85/15, 41/16.
62. Hrvatski zavod za poljoprivrednu savjetodavnu službu (2012). Kalkulacije vinogradarskih i vinarskih kultura 2012. Dostupno na <http://www.agroklub.com/vinogradarstvo/kalkulacije-vinogradarskih-i-vinarskih-kultura-2012/7422/>. Pristupljeno 06. 07. 2014.
63. Inderhees, P. G., Theuvsen, L. (2009). Farmers' strategies in globalizing markets: Empirical results from Germany. *Journal of International Food and Agribusiness Marketing* 21(4): 253-268.

64. Jaffee, S., Siegel, P., Andrews, C. (2010). Rapid Agricultural Supply Chain Risk Assessment: A Conceptual Framework. The World Bank. Washington. D. C. Dostupno na: [http://www.agriskmanagementforum.org/sites/agriskmanagementforum.org/files/Documents/RapApRiskAssessment\\_Framework\\_Final\\_Web.pdf](http://www.agriskmanagementforum.org/sites/agriskmanagementforum.org/files/Documents/RapApRiskAssessment_Framework_Final_Web.pdf). Pristupljeno 16. 12. 2013.
65. Ježovita, A., Žager, L. (2014). Ocjena zaduženosti poduzeća pokazateljima profitabilnosti. Zbornik Ekonomskog fakulteta u Zagrebu 12(1): 1-22.
66. Jordan, D., Aguilar, D., Gilinsky, A. (2010). Benchmarking Winery Financial Performance. Wine Business Monthly 11: 60-67.
67. Kaufman, G. M., Thomas, H. (1977). Modern Decision Analysis. Richard Clay (The Chaucer Press) Ltd. Great Britain.
68. Knoeber, C. R., Thurman, W. N. (1995). Don't Count Your Chickens...": Risk and Risk Shifting in the Broiler Industry, American Journal of Agricultural Economics 77(3): 486-496.
69. Kobzar, O. (2006). Whole-farm risk management in arable farming: portfolio methods for farm-specific business analysis and planning. Doktorska disertacija. Wageningen Universiteit. Wageningen, Nizozemska.
70. Köprülü, O. (2014). Decision-Making Process and Risk Analysis of Agricultural Market Economy in Turkey: A Case Study From Kalecik Region Wine Producers. European Journal of Research on Education 2(6): 55-61.
71. Leat, P., Giha, C. R. (2013). Risk and resilience in agri-food supply chains: the case of the ASDA PorkLink supply chain in Scotland. Supply Chain Management. An International Journal 18(2): 219-231.
72. Lemke, F., Petersen, H. L. (2013). Teaching reputational risk management in the supply chain. Supply Chain Management: An International Journal 18(4): 413-429.
73. Lien, G., Hardaker, J. B. (2001). Whole-farm planning under uncertainty: impacts of subsidy schemes and utility function on portfolio choice in Norwegian agriculture. European Review of Agricultural Economics 28(1): 17-36.
74. Lombardi, P., Dal Bianco, A., Freda, R., Caracciolo, F., Cembalo, L. (2016). Development and trade competitiveness of the European wine sector: A gravity analysis of intra-EU flows. Wine Economics and Policy 5: 50-59.
75. Maletić, E., Kovačić, D., Njavro, M. (2012). Strategija razvoja vinarstva i vinogradarstva Dubrovačko neretvanske županije. Dostupno na: [www.edubrovnik.org/BACKUP\\_2016/Strategija\\_vin\\_DNZ.pdf](http://www.edubrovnik.org/BACKUP_2016/Strategija_vin_DNZ.pdf). Pristupljeno 22. 03. 2013.
76. Marušić, M., Vranešić, T. (2001). Istraživanje tržišta, V izmijenjeno i dopunjeno izdanje, ADECO, Zagreb.

77. Matarazzo, A., Clasadonte, M. T., Matarazzo, B. (2008). Strumenti Finanziari e Mercato del Vino nelle Esperienze Internazionali ed Italiane. U 31st World Vine and Wine Congress of the OIV. Verona: 1-8.
78. Matić, B., Wittine, Z., Čenan, D. (2010). Country Risk Management Practices – Evidence from Croatian Companies. 2010 EABR & ETLC Conference Proceedings Dublin, Ireland: 258-265.
79. Mazzarol, T., Limnios, E. M., Reboud, S. (2013). Co-operatives as a strategic network of small firms: Case studies from Australian and French co-operatives. *Journal of Co-operative Organization and Management* 1(1): 27-40.
80. McElwee, G., Anderson, A., Vesala, K. (2006). The strategic farmer: a cheese producer with cold feet?. *Journal of Business Strategy* 27(6): 65-72.
81. Meuwissen, M. P. M., Hardaker, B., Huirnei, R. B. M., Dijkhuizen, A. A. (2001). Sharing risks in agriculture; principles and empirical results. *Netherlands Journal of Agricultural Science* 49: 343-356.
82. Mikić, M. (2009). Upravljanje troškovima u malim i srednjim proizvodnim poduzećima *Zbornik Ekonomskog fakulteta u Zagrebu* 7(1): 161-176.
83. Milat, V. (2005). Stanje u vinogradarstvu i vinarstvu Republike Hrvatske. *Pregledni rad. Glasnik zaštite bilja* 6/2005: 5-15.
84. Miller, A., Dobbins, C., Pritchett, J., Boehlje, M., Ehmke, C. (2004). Risk Management for Farmers. Staff Paper 04-11. Department of Agricultural Economics Purdue University. Dostupno na: <http://ageconsearch.umn.edu/bitstream/28640/1/sp040011.pdf>. Pristupljeno 29. 09. 2014.
85. Miloš Sprčić, D., Radić, D. (2011). Kvantifikacija izloženosti rizicima - usporedba i ocjena metoda VaR i CFaR. *Zbornik Ekonomskog fakulteta u Zagrebu* 9(1): 51-66.
86. Ministarstvo financija Republike Hrvatske Porezna uprava (2016). Hrvatski porezni sustav. Dostupno na: [https://www.porezna-uprava.hr/HR\\_publicacije/Prirucnici\\_brosure/PorezniSustav\\_2012.pdf](https://www.porezna-uprava.hr/HR_publicacije/Prirucnici_brosure/PorezniSustav_2012.pdf). Pristupljeno 28. 06. 2017.
87. Ministarstvo poljoprivrede Republike Hrvatske (2008). Nacionalni program pomoći sektoru vina 2014. do 2018. Dostupno na: <http://www.mps.hr/default.aspx?id=9527>. Pristupljeno 04. 04. 2016.
88. Ministarstvo regionalnog razvoja i fondova Europske unije Republike Hrvatske *Europski strukturni i investicijski fondovi* (2012, a). Instrumenti zajedničke poljoprivredne politike 2007–2013.. Dostupno na: <http://www.strukturnifondovi.hr/instrumenti-zajednicke-poljoprivredne-politike-2007-2013>. Pristupljeno 22. 06. 2017.
89. Ministarstvo regionalnog razvoja i fondova Europske unije Republike Hrvatske *Europski strukturni i investicijski fondovi* (2012, b). Instrumenti zajedničke poljoprivredne

politike 2007 - 2013.. Dostupno na: <http://www.strukturnifondovi.hr/eu-fondovi>. Pristupljeno 22. 06. 2017.

90. Ministarstvo regionalnog razvoja i fondova Europske unije Republike Hrvatske. Europski strukturni i investicijski fondovi (2012, c). Instrumenti zajedničke poljoprivredne politike 2007 - 2013.. Dostupno na: <http://www.strukturnifondovi.hr/program-ruralnog-razvoja-2014-2020>. Pristupljeno 22. 06. 2017.

91. Ministarstvo turizma Republike Hrvatske (2010). Turizam u brojkama 2015. Zagreb: Ministarstvo turizma Republike Hrvatske. Dostupno na: <http://www.mint.hr/UserDocsImages/TUB2015HR.pdf>. Pristupljeno 27. 02. 2017.

92. Montezemolo, S. C. (2006). Profitability, growth and corporate value of the wine companies (work in progress). France, Montpellier. Dostupno na: <http://academyofwinebusiness.com/wp-content/uploads/2010/05/Cordero.pdf>. Pristupljeno 20. 04. 2017.

93. Newton, S. K., Gilinsky, A. Jr., Jordan, D. (2015). Differentiation strategies and winery financial performance: An empirical investigation. *Wine Economics and Policy* 4: 88-97.

94. Novotná, M., Svoboda, J. (2014). The economic results of farms in the Czech Republic. *Journal of Central European Agriculture* 15(4): 31-50.

95. Njavro, M. (2017). Predavanja iz upravljanja rizikom, interno.

96. Njavro, M., Jakobović, S., Budimir, V. (2005). Upravljanje rizikom na voćarskim i vinogradarsko - vinarskim gospodarstvima Slavonije i Baranje. *Poljoprivreda* 11(1): 31-37.

97. Obuchowski, J. (2006). The Strategic Benefits of Managing Risk Publication. *MIT Sloan Management Review* 47.3: 6-7.

98. Odbor za standarde financijskog izvještavanja (2015). Hrvatski standard financijskog izvještavanja. Zagreb: Narodne novine 86/15.

99. O'Donoghue, E. (2013). Risk management. Washington: U. S. Department of Agriculture - Economic Research Service. Dostupno na: <http://www.ers.usda.gov/topics/farm-practices-management/risk-management/risk-in-agriculture.aspx#.UpYc6-KzJcp>, <http://www.ers.usda.gov/topics/farm-practices-management/risk-management/risk-management-strategies.aspx#.Ux8CrIW7Rco>. Pristupljeno 24. 11. 2013.

100. Orr, S. (1999). The role of quality management in manufacturing strategy: Experiences from the Australian wine, industry. Publication info: *Total Quality Management* 10.2: 271-279.

101. Pallant, J. (2005). SPSS survival manual: a step by step guide to data analysis using SPSS. Crows Nest NSW (Sydney): Allen & Unwin.



102. Palepu, K. G., Healy, P. M., Bernard, V. L., Peek, E. (2007). *Business Analysis and Valuation: IFRS Edition - Test and Cases*. London: Thomson Learning iz Ježovita, A., Žager, L. (2014). Ocjena zaduženosti poduzeća pokazateljima profitabilnosti. *Zbornik Ekonomskog fakulteta u Zagrebu* 12(1): 1-22.
103. Porter, M., Bond, G. C. (2006). The California Wine Cluster. *Harvard Business School* 9-799-124.
104. Porter, M., Solvell, O. (2003). The Australian Wine Cluster. *Harvard Business School* 9-703-492.
105. Redhead, K. (1997). *Financial Derivatives – An Introduction to Futures, Forwards, Options and Swaps*, Prentice Hall Europe, London iz Tuškan, B. (2009). Upravljanje rizicima upotrebom financijskih derivata u RH. *Zbornik Ekonomskog fakulteta u Zagrebu* 7(1): 107-120.
106. Repar, L., Njavro, M., Par, V. (2012). Menadžment i vođenje u trgovačkim društvima u agrobiznisu (Management and Leadership in Agribusiness Companies). *Journal of Central European Agriculture* 13(1): 109-122.
107. Reynolds, S., Meyer, F., Cutts, M., Vink, D. (2009). Modeling Long-term Commodities: the Development of a Simulation Model for the South African Wine Industry within a Partial Equilibrium Framework. *Journal of Wine Economics* 4(2): 201-218.
108. Richardson, J. W., Schumann, K. D., Feldman, P. A. (1997). prezentacija Simetar. Texas A&M University.
109. Saes, M. S. M., Souza, M. C. M., Otani, M. N. (2003). Strategic alliances and sustainable coffee production: The shaded system of Baturite, State of Ceara, Brazil. *International Food and Agribusiness Management Review* 6(2): 19-29.
110. Seccia, A., Santeramo, F. G., Nardone, G. (2016). Risk management in wine industry: A review of literature. 39th World Congress of Vine and Wine. BIO Web of Conferences. DOI: 10.1051/bioconf/20160703014.
111. Sellers, R., Alampi-Sottini, V. (2016). The influence of size on winery performance: Evidence from Italy. *Wine Economics and Policy* 5: 33-41.
112. Slywotzky, A. J., Drzik, J. (2005). Countering the Biggest Risk of All. *Harvard Business Review* 83(4): 78-88.
113. Sheehan, N. T. (2010). A risk-based approach to strategy execution. *The Journal of Business Strategy* 31.5: 25-37.
114. Sherrick, B. J., Barry, P. J., Ellinger, P. N., Schnitkey, G. D. (2004). Factors influencing farmers' crop insurance decisions. *American journal of agricultural economics* 86(1): 103-114.

115. Smrkulj, H., Njavro, M. (2016). Risk management on the winegrowing farms at Northwest Croatia (Upravljanje rizikom na vinarsko-vinogradarskim gospodarstvima Sjeverozapadne Hrvatske). *Journal of Central European Agriculture* 17(1): 221-235.
116. Sommer, P., Brown, I. (2011). Reducing Systemic Cybersecurity Risk, OECD. Dostupno na: <https://www.oecd.org/gov/risk/46889922.pdf>. Pristupljeno 20. 04. 2017.
117. Sprčić, D. M. (2007). Corporate Risk Management Rationales: Evidence from Croatian Companies. *Ekonomski pregled* 58(9-10): 497-521.
118. Sprčić, D. M., Šević, Ž. (2008). Comparative Analysis of Corporate Risk Management Practices in Croatian and Slovenian Companies. *Zagreb International Review of Economics and Business* 11(2): 63-80.
119. Sprčić, D. M., Tekavčić, M., Šević, Ž. (2008). Corporate Risk Management Practices in Croatian Companies. *Ekonomski pregled* 59(7-8): 344-369.
120. Sučić, J. H., Sprčić, D. M., Zoričić, D. (2011). Upravljanje financijskim rizicima u hrvatskim poduzećima. *Zbornik Ekonomskog fakulteta u Zagrebu* 9(1): 71-88.
121. Székely, C., Pálinkás, P. (2009). Agricultural Risk Management in the European Union and in the USA. *Studies in Agricultural Economics* 109: 55-72. Dostupno na: [http://ageconsearch.umn.edu/bitstream/49193/2/No.%20109\\_4.pdf](http://ageconsearch.umn.edu/bitstream/49193/2/No.%20109_4.pdf). Pristupljeno 25. 05. 2017.
122. Šarlija (2009). Sveučilište Josipa Juraja Strossmayera u Osijeku. Dostupno na: [http://www.efos.unios.hr/financijski-menadzment-za-poduzetnike/wp-content/uploads/sites/144/2013/04/microsoft\\_word\\_-\\_financijska\\_analiza.doc.pdf](http://www.efos.unios.hr/financijski-menadzment-za-poduzetnike/wp-content/uploads/sites/144/2013/04/microsoft_word_-_financijska_analiza.doc.pdf). Pristupljeno: 15. 01. 2018.
123. Šarlija, N., Penavin, S., Harc, M. (2009). Predviđanje nelikvidnosti poduzeća u Hrvatskoj. *Zbornik Ekonomskog fakulteta u Zagrebu* 7(2): 21-36.
124. Šošić, I., Serdar, V. (1997). Uvod u statistiku, X izdanje, Školska knjiga Zagreb, Grafički zavod Hrvatske.
125. Teach, E. (1997). Microsoft's Universe of Risk. CFO: 69-71 iz Detre, J., Briggeman, B., Boehlje, M., Gray, A. W. (2006). Scorecarding and Heat Mapping: Tools and Concepts for Assessing Strategic Uncertainty. *International Food and Agribusiness Management Review* 9(1): 1-22.
126. The Institute of Risk Management (IRM), The Association of Insurance and Risk Managers (AIRMIC), The National Forum for Risk Management in the Public Sector (ALARM) (2002). A Risk Management Standard, published by AIRMIC, ALARM, IRM: 2,4. Dostupno na: [http://www.theirm.org/publications/documents/Risk\\_Management\\_Standard\\_030820.pdf](http://www.theirm.org/publications/documents/Risk_Management_Standard_030820.pdf). Pristupljeno 01. 03. 2016.

127. The International Organisation of Vine and Wine (OIV) (2016). State of the vitiviniculture world market. Dostupno na: <http://www.oiv.int/public/medias/4710/oiv-noteconjmars2016-en.pdf>. Pristupljeno 28. 05. 2017.
128. The World Bank (Agriculture Risk Management Team) (2011). Agricultural risks and risk management iz Agriculture and Rural Development Discussion Paper. Weather indeks insurance for Agriculture. Dostupno na: [https://agriskmanagementforum.org/sites/agriskmanagementforum.org/files/Chapter\\_1\\_WII\\_Paper\\_Nov\\_2011.pdf](https://agriskmanagementforum.org/sites/agriskmanagementforum.org/files/Chapter_1_WII_Paper_Nov_2011.pdf). Pristupljeno 24. 11. 2013.
129. Tomašević, M. (2007). Matematičke metode kao čimbenik odlučivanja o uspješnosti menadžmenta. *Informatologia* 40: 94-100.
130. Tot, I., Par, V., Grgić, I. (2008). Percepcija rizika u proizvodnji šećerne repe. U 43. hrvatski i 3. međunarodni simpozij agronoma, Opatija: Agronomski fakultet Sveučilišta u Zagrebu: 175-179.
131. Toth, M., Lančarič, D., Piterkova, A., Savov, R. (2014). Systematic Risk in Agriculture: A Case of Slovakia. *Agris on-line Papers in Economics and Informatics* VI(4): 185-193.
132. Townsend, R. (2005). Weather Insurance in Semi-Arid India. Paper prepared for the Commodity Risk Management Group, Agricultural and Rural Development Department, ESW, The World Bank, Washington, D. C. iz The World Bank (2005). Managing Agricultural Production Risk, Innovations in Developing Countries, report no. 32727-GLB, Washington DC, SAD: The World Bank.
133. Tudisca, S., di Trapani, A. M., Sgroi, F., Testa, R. (2013). Marketing Strategies for Mediterranean Wineries Competitiveness The Case of Pantelleria. *Quality access to success* 14(137): 101-106.
134. Turvey, C. G., Bogan, V. L., Yu, C. (2012). Small businesses and risk contingent credit. *The Journal of Risk Finance* 13(5): 491-506.
135. Uddin, M. N., Quaddus, M., Islam, N. (2010). Knowledge asset and inter-organizational relationship in the performance of Australian beef supply chain. U 14th Pacific Asia Conference on Information Systems, Taiwan: PACIS, 725-737.
136. Vesala, K. M., Peura, J., McElwee, G. (2007). The split entrepreneurial identity of the farmer. *Journal of Small Business and Enterprise Development* 14(1): 48-63.
137. Vidučić, Lj., Pepur, S., Šimić, M. (2015) Financijski menadžment. *RRIF plus*: 66-67 iz Deković, Ž., Žaja, J., Smiljčić, I. (2017). Rizik i financijski menadžment. *Zbornik radova Veleučilišta u Šibeniku* 1-2: 123-139.
138. Viviani, J. L. (2006). Risk management of the agricultural income: the inter-Rhône reserve. *British Food Journal* 108(4): 290-305.

139. Vlada Republike Hrvatske (2007). Odluka o nacionalnoj klasifikaciji djelatnosti 2007. (NKD 2007.). Narodne novine 58/07.
140. Wysocki, A. F., Peterson, H. C., Harsh, S. B. (2003). Quantifying Strategic Choice Along the Vertical Coordination Continuum. *International Food and Agribusiness Management Review* 6(3): 113-134.
141. Žager, K., Mamić-Sačar, I., Sever, S., Žager, L. (2008). Analiza financijskih izvještaja. Masmedia, Zagreb.

## 9. ŽIVOTOPIS

Željka Bedek rođena je 10. svibnja 1979. u Zagrebu. Nakon završetka zagrebačke I ekonomske škole upisuje Agronomski fakultet Sveučilišta u Zagrebu. Diplomirala je 2004. godine na usmjerenju Agroekonomika s diplomskim radom pod nazivom «Ekonomska učinkovitost uzgoja kunića na obiteljskom gospodarstvu». Od 2005. od 2009. godine zaposlena je u Hrvatskom zavodu za vinogradarstvo i vinarstvo, a od 2009. godine u Hrvatskom centru za poljoprivredu, hranu i selo.

Objavljeni radovi:

1. Bedek, Ž., Njavro, M. (2016). Risk and Competitiveness in Agriculture with emphasis on wine sector in Croatia. *Abstract 10* (1): 11-18.
2. Bedek, Ž., Njavro, M., Jakšić, L. (2015). Važnost strateškog upravljanja u modernom agrobiznisu - literaturni pregled i lekcije za Hrvatsku. *Agronomski glasnik* 4-6: 241.
3. Bedek, Ž., Njavro, M. (2015). Strategic Risk Management in Croatian wine industry upon EU accession. *New Medit* 14 (1): 53-60.
4. Grgić, I., Kovačić, D., Bedek, Ž. (2010). Liberalizacija hrvatskog tržišta vina – izazov i/ili prijetnja. 45. hrvatski i 5. Međunarodni simpozij agronoma, Opatija, 15. do 19. veljače 2010.
5. Bedek, Ž., Gašparec-Skočić, Lj. (2010). Ponuda vina na vinskim cestama Istarske županije. 45. hrvatski i 5. Međunarodni simpozij agronoma, Opatija, 15. do 19. veljače 2010.
6. Njavro, M., Bedek, Ž., Smrek, S. (2009). Facing climate change in wine sector with innovative risk management strategies. *Proceedings of 32th World Vine and Wine Congress of the OIV, Zagreb*, 28. lipnja do 03. srpanj 2009.
7. Bedek, Ž., Mihaljević, B., Bosankić, G. (2009). Economic importance of graševina variety cv.riesling italico, in the Republic of Croatia. *Proceedings of 32th World Vine and Wine Congress of the OIV, Zagreb*, 28. lipnja do 03. srpanj 2009.
8. Gašparec-Skočić, Lj., Bedek, Ž., Banić, B. (2009). Wine marketing trends in the Republic of Croatia. *Proceedings of 32th World Vine and Wine Congress of the OIV, Zagreb*, 28. lipnja do 03. srpanj 2009.
9. Majnarić, F., Mihaljević, B., Bedek, Ž. (2009). Stamp – proof of traceability in wine quality control in the Republic of Croatia. *Proceedings of 32th World Vine and Wine Congress of the OIV, Zagreb*, 28. lipnja do 03. srpanj 2009.

## 10. PRILOZI

Prilog 1: Anketa „Analiza stanja vinarskog sektora u Republici Hrvatskoj“

Poštovani,

Ijubazno Vas molimo da ispunite anketu u nastavku, a za potrebe izrade znanstvenog rada Upravljanje strateškim rizikom vinarija u Hrvatskoj poslijediplomskog doktorskog studija Ekonomika poljoprivrede.

Namjera je ove ankete kvantificirati snage, slabosti, prilike i prijetnje. U prethodnim koracima istraživanja izdvojene su dolje navedene snage, slabosti, prilike i prijetnje.

Za moguće komentare i nadopune dostupna je posljednja stranica ankete.

Molimo vas da na sva pitanja odgovorite, a ako imate dodatnih pitanja ili nejasnoća slobodno se javite na e-mail [zbedek@gmail.com](mailto:zbedek@gmail.com).

Procijenjeno vrijeme ispunjenja ankete – 10 minuta.

S poštovanjem,

doc. dr. sc. Mario Njavro

Željka Bedek, dipl. ing. agr.

1. Molimo Vas da ocijenite snage vinarstva i vinogradarstva u RH na skali od 1 do 5, pri čemu 1 predstavlja najmanju vrijednost.

		Snage				
1	Okolišni uvjeti za vinogradarsku proizvodnju	1	2	3	4	5
2	Vrhunskih položaji za uzgoj visokokvalitetnog grožđa	1	2	3	4	5
3	Autohtone sorte vinove loze	1	2	3	4	5
4	Mogućnosti razvoja ekološkog vinogradarstva	1	2	3	4	5
5	Tradicija bavljenja uzgojem vinove loze	1	2	3	4	5
6	Tržna pozicija i imidž vinorodnog područja na domaćem tržištu	1	2	3	4	5
7	Povjerenje potrošača	1	2	3	4	5
8	Turizam	1	2	3	4	5
9	Veći broj školovanih enologa - baza stručnjaka u proizvodnji	1	2	3	4	5

2. Molimo Vas da ocijenite slabosti vinarstva i vinogradarstva u RH na skali od 1 do 5, pri čemu 1 predstavlja najmanju vrijednost.

		Slabosti				
1	Stari vinogradi u lošoj kondiciji	1	2	3	4	5
2	Male usitnjene površine	1	2	3	4	5
3	Mali broj površina pod navodnjavanjem	1	2	3	4	5
4	Otežana ili nemoguća primjena suvremene tehnologije	1	2	3	4	5
5	Zastarjela tehnologiju	1	2	3	4	5
6	Orijentiranost na prinos	1	2	3	4	5
7	Male potpore za otežane uvjete gospodarenja	1	2	3	4	5
8	Problem radne snage	1	2	3	4	5
9	Neorganiziranost vinogradara	1	2	3	4	5
10	Slaba informiranost i poduzetničke vještine	1	2	3	4	5
11	Cjenovna ne konkurentnost	1	2	3	4	5
12	Zalihe vina	1	2	3	4	5
13	Nedostatka marketinga vina	1	2	3	4	5
14	Niske cijene za prodaju vina u rinfuzi	1	2	3	4	5
15	Sivo/crno tržište, šverc grožđa i vina	1	2	3	4	5
16	Problemi u plasmanu vina u ugostiteljstvu	1	2	3	4	5
17	Skupa i složena birokracija	1	2	3	4	5
18	Manjak stručne pomoći i visoke cijene konzaltinga	1	2	3	4	5

3. Molimo Vas da ocijenite prema važnosti prilike vinarstva i vinogradarstva u RH na skali od 1 do 5, pri čemu 1 predstavlja najvažniju vrijednost.

		Prilike				
1	Nove tehnologije	1	2	3	4	5
2	Važnost ekološkog uzgoja	1	2	3	4	5
3	Rast svijesti o nužnosti održivog razvoja i očuvanju tradicijskog, kulturnog i povijesnog nasljeđa;	1	2	3	4	5
4	Regulacija tržišta vina u EU	1	2	3	4	5
5	Povećanje tržišta – ulazak u EU	1	2	3	4	5
6	Veći protok ideja, ljudi i kapitala	1	2	3	4	5
7	Porast potražnje za posebnim vinima (vrhunska kakvoća, autohtone sorte, ekološka proizvodnja)	1	2	3	4	5
8	Razvoj tržišta/dolazak novih vinskih poduzetnika	1	2	3	4	5
9	Porast turističke potražnje	1	2	3	4	5
10	Razvoj elitnog turizma	1	2	3	4	5
11	Razvoj agroturizma i vinskog turizma	1	2	3	4	5
12	Obveza planiranja ruralnog razvoja	1	2	3	4	5
13	EU programi za ruralni prostor, očuvanje tradicionalnih gospodarskih aktivnosti i očuvanje bioraznolikosti	1	2	3	4	5
14	Novi oblici prodaje - Web prodaja	1	2	3	4	5

4. Molimo Vas da ocijenite prema važnosti prijetnje vinarstva i vinogradarstva u RH na skali od 1 do 5, pri čemu 1 predstavlja najvažniju vrijednost.

		Prijetnje/Rizici				
1	Promjena strukture i teksture tla upotrebom teške mehanizacije	1	2	3	4	5
2	Klimatske promjene, problem navodnjavanja	1	2	3	4	5
3	Zaštita od bolesti i štetnika	1	2	3	4	5
4	Uvoz jeftinog grožđa i vina	1	2	3	4	5
5	Pad cijena vina i grožđa	1	2	3	4	5
6	Ponuda jednako kvalitetnih vina po nižim cijenama	1	2	3	4	5
7	Gospodarska kriza i pad potražnje vina	1	2	3	4	5
8	Gospodarska kriza i pad kupovne moći domaćeg stanovništva;	1	2	3	4	5
9	Ukidanje carina prema EU i smanjenje carina prema „novim“ vinskim zemljama	1	2	3	4	5
10	Preferencije tržišta/drugi tip vina	1	2	3	4	5
11	Koncentracija vinske industrije	1	2	3	4	5
12	Daljnje jačanje trgovačkih lanaca	1	2	3	4	5
13	Manjak motivacije za vinogradarstvo	1	2	3	4	5
14	Kriza u zadrugarstvu	1	2	3	4	5
15	Neplaćanje i nelikvidnost	1	2	3	4	5
16	Crno tržište i odsustvo inspekcijskog nadzora	1	2	3	4	5
17	Nesređeno i komplicirano zakonodavstvo	1	2	3	4	5
18	Masovni turizam, onečišćenje okoliša,	1	2	3	4	5
19	Nesređeno vlasništvo nad nekretninama	1	2	3	4	5
20	Gubitak identiteta kroz globalizacijske procese;	1	2	3	4	5

Komentar:

---



---



---



---

Hvala na suradnji !



## Prilog 2: Izvori literature u anketi „Strateško upravljanje rizikom vinarija u Hrvatskoj“

Za pitanja koja su obuhvaćala vjerojatnost nastanka rizika i posljedicu rizika postoje i sljedeći izvori iz literature:

1. klimatske promjene (prirodne nepogode,...): Jaffee i sur. (2010), Tot i sur. (2008),
2. onečišćenje okoliša (ekologija): Jaffee i sur. (2010), Njavro i sur. (2005),
3. izostanak navodnjavanja u kritičnom razdoblju (suša): prema Maletić i sur. (2012),
4. pojava bolesti i štetnika: Njavro i sur. (2005), Tot i sur. (2008),
5. rizik menadžerske pogreške: prema Repar i sur. (2012),
6. značajne promjene u strukturi tla uzrokovane upotrebom teške mehanizacije (pr. zbijanje tla, ...): Maletić i sur.. (2012),
7. stari vinogradi u „lošoj kondiciji“: Maletić i sur. (2012),
8. promjene u tehnologiji proizvodnje (zastarjela tehnologija, nedovoljno uvođenje nove tehnologije): Njavro i sur. (2005), Maletić i sur. (2012), Tot i sur. (2008),
9. nedovoljna kontrola kvalitete (propusti u kontroli kvalitete): Njavro i sur. (2005),
10. promjena poslovne politike na orijentiranost na prinos: prema Maletić i sur. (2012),
11. ovisnost o kooperantima: prema Lemke i Peterson(2013),
12. rizik loše reputacije vina: prema Lemke i Peterson (2013), Maletić i sur. (2012),
13. reputacijski rizik tvrtke: prema Lemke i Peterson (2013), Maletić i sur. (2012),
14. gubitak identiteta tvrtke kroz globalizacijske procese: Maletić i sur. (2012),
15. nelikvidnost poduzeća: Maletić i sur. (2012),
16. dugo razdoblje naplate, poštivanje ugovornih obveza (kupci i dobavljači), nejasno i nedovoljno definirani uvjeti, neplaćanje: Njavro i sur. (2005), Tot i sur. (2008),
17. zalihe vina: Maletić i sur. (2012),
18. niska educiranost zaposlenika, manjak/višak zaposlenika: Njavro i sur. (2005),
19. pogreške zaposlenika, bolovanja, smrt...: Njavro i sur. (2005),
20. promjenjivost cijene *inputa* (rast cijena *inputa*): Njavro i sur. (2005), Tot i sur. (2008),
21. promjenjivost cijene vina (pad cijena *outputa*): Njavro i sur. (2005), Maletić i sur. (2012), prema Tot i sur. (2008),
22. cjenovna ne konkurentnost: Maletić i sur. (2012),
23. visoka cijena kapitala (visoke kamatne stope): Njavro i sur. (2005), Tot i sur. (2008),
24. promjenjivost kamatnih stopa: Njavro i sur. (2005), Tot i sur. (2008),
25. jačanje konkurencije/jačanje konkurentskih tvrtki: The World Bank (Agriculture Risk Management Team) (2011), Slywotzky i Drzik (2005),
26. jačanje pregovaračke snage dobavljača: Slywotzky i Drzik (2005),
27. jačanje pregovaračke snage potrošača, trgovačkih lanaca, restorana,...: prema Porterov model pet sila, David (2011),

28. razvoj zamjenskih proizvoda (preferencije potrošača se mijenjaju u korist piva, ...): Njavro i sur. (2005), prema Maletić i sur. (2012),
29. promjene preferencija tržišta (...drugi „tip“ vina): Maletić i sur. (2012), prema Tot i sur. (2008),
30. promjene poljoprivredne i trgovinskih politika (EU, CEFTA,...): Njavro i sur. (2005),
31. nesigurnosti regulatornih i zakonskih politika: prema Maletić i sur. (2012),
32. društveno-politička situacija (gospodarske sankcije, ...): prema Jaffee i sur. (2010),
33. nedovoljan nadzor tržišta, crno tržište,...:Maletić i sur. (2012),
34. skupa i složena državna administracija: prema Maletić i sur. (2012),
35. nedovoljne potpore za otežane uvjete gospodarenja: Maletić i sur. (2012),
36. ovisnost o turističkoj potražnji: prema Maletić i sur. (2012),
37. pad potražnje za vinom uzrokovan gospodarskom krizom: prema Maletić i sur. (2012),
38. pad kupovne moći uzrokovan gospodarskom krizom: prema Maletić i sur. (2012),
39. IT nesigurnost (Cybersecurity Rizik): Sommer i Brown (2011),
40. industrijska špijunaža: Detre i sur. (2006) sekundarni izvor prema Teach (1997).

U pitanjima vezanim za strategije, važnost primjene i učestalost primjene upravljanja rizikom postoje sljedeći izvori iz literature:

1. proizvodna diversifikacija tvrtke: Njavro i sur. (2005), prema O'Donoghue (2013),
2. zemljopisna i vremenska diversifikacija proizvoda: Njavro i sur. (2005), The World Bank (Agriculture Risk Management Team) (2011), Tot i sur. (2008),
3. pridržavanje tehnologije i agrotehničkih rokova: Njavro i sur. (2005), Tot i sur. (2008),
4. korištenje vlastitog zemljišta: Njavro i sur. (2005), Tot i sur. (2008),
5. navodnjavanje: Njavro i sur. (2005), Tot i sur. (2008),
6. protumrazni i protugradni sustav: Njavro i sur. (2005),
7. zalihe rezervnih dijelova: Njavro i sur. (2005), Tot i sur. (2008),
8. lizing i/ili najam opreme i mehanizacije: Njavro i sur. (2005), Tot i sur. (2008),
9. sustav nabave i logistike (repromaterijal, ...): prema Grgić i sur. (2010),
10. organizirana nabava inputa: Njavro i sur. (2005), Tot i sur. (2008),
11. proizvodnja za poznatog kupca (robne marke,...): Njavro i sur. (2005), Tot i sur. (2008).
12. prodaja proizvoda putem više različitih kanala: Njavro i sur. (2005), Tot i sur. (2008),
13. zalihe vina: prema The World Bank (Agriculture Risk Management Team) (2011), prema Maletić i sur. (2012),
14. osiguranje (opreme, objekata...): Njavro i sur. (2005), O'Donoghue, (2013), Tot i sur. (2008),
15. zalihe gotovine i ostale rezerve u slučaju financijskih rizika: Njavro i sur. (2005), O'Donoghue (2013), Tot i sur. (2008),
16. *Hedging*: O'Donoghue (2013),
17. Faktoring: Hrvatski sabor (2014),
18. prodajni ugovori, ugovori s kooperantima: prema Njavro i sur. (2005), O'Donoghue (2013), Tot i sur. (2008),
19. prodaja imovine: The World Bank (Agriculture Risk Management Team) (2011),
20. korištenje stručnih i konzultantskih usluga: Njavro i sur. (2005), Tot i sur. (2008),
21. ljudski potencijali (dovoljan broj radnika u „vrhovima“ proizvodnje): Njavro i sur. (2005), Tot i sur. (2008),
22. privremeno zapošljavanje: O'Donoghue (2013),
23. stalno učenje i informiranost (tečajevi, treninzi): Njavro i sur. (2005), Vesala i sur. (2007), McElwee i sur. (2006),
24. konkurentsko udruživanje (klasteri - vertikalno i horizontalno): O'Donoghue, (2013), Saes i sur. (2003),
25. korištenje programa potpore (nacionalni i EU programi)

Prilog 3: Proizvodi industrijske proizvodnje (sumarna tabela proizvodnje zbrojena za vlastiti račun i na osnovi ugovora) za vino, mirna vina, specijalna vina, pjenušava vina i mošt

Godina	NAZIV PROIZVODA (NIP - 1593121500)
2005.	Pjenušava vina od svježā groŹđa s volumnim udjelom stvarnog alkohola od > 8,5%
	Bijela vina iz odreĊenih geografskih podruĉja (kvalitetna vina proizvedena u posebnim regijama)
	Bijela vina (ostala), koja nisu kvalitetna vina proizvedena u posebnim regijama
	Vina i mošt, sprijeĉene ili zaustavljene fermentacije dodavanjem alkohola u otopini s CO <sub>2</sub> , tlaka >=
	Kvalitetna vina i mošt sprijeĉene ili zaustavljene fermentacije dodavanjem alkohola, kvalitetna vina
	Vina i mošt sprijeĉene ili zaustavljene fermentacije dodavanjem alkohola, alkoholne jakosti >= 15%
	Port, Madeira, Sherry, Tokay i ostala vina s > 15% alkohola
2006.	Pjenušava vina od svježā groŹđa s volumnim udjelom stvarnog alkohola od > 8,5%
	Bijela vina iz odreĊenih geografskih podruĉja (kvalitetna vina proizvedena u posebnim regijama)
	Bijela vina (ostala), koja nisu kvalitetna vina proizvedena u posebnim regijama
	Vina i mošt, sprijeĉene ili zaustavljene fermentacije dodavanjem alkohola u otopini s CO <sub>2</sub> , tlaka >=
	Kvalitetna vina i mošt sprijeĉene ili zaustavljene fermentacije dodavanjem alkohola, kvalitetna vina
	Vina i mošt sprijeĉene ili zaustavljene fermentacije dodavanjem alkohola, alkoholne jakosti >= 15%
	Port, Madeira, Sherry, Tokay i ostala vina s > 15% alkohola
2007.	Pjenušava vina od svježā groŹđa s volumnim udjelom stvarnog alkohola od > 8.5%
	Bijela vina iz odreĊenih geografskih podruĉja (kvalitetna vina proizvedena u posebnim regijama)
	Bijela vina (ostala), koja nisu kvalitetna vina proizvedena u posebnim regijama
	Vina i mošt, sprijeĉene ili zaustavljene fermentacije dodavanjem alkohola u otopini s CO <sub>2</sub> , tlaka >=
	Kvalitetna vina i mošt sprijeĉene ili zaustavljene fermentacije dodavanjem alkohola, kvalitetna vina
	Vina i mošt sprijeĉene ili zaustavljene fermentacije dodavanjem alkohola, alkoholne jakosti >= 15%
	Port, Madeira, Sherry, Tokay i ostala vina s > 15% alkohola
2008.	Bijela vina iz odreĊenih geografskih podruĉja (kvalitetna vina proizvedena u posebnim regijama)
	Bijela vina (ostala), koja nisu kvalitetna vina proizvedena u posebnim regijama

	Vina i mošt, spriječene ili zaustavljene fermentacije dodavanjem alkohola u otopini s CO <sub>2</sub> , tlaka $\geq$
	Kvalitetna vina i mošt spriječene ili zaustavljene fermentacije dodavanjem alkohola, kvalitetna vina
	Vina i mošt spriječene ili zaustavljene fermentacije dodavanjem alkohola, alkoholne jakosti $\leq$ 15%
	Port, Madeira, Sherry i ostala vina s $>$ 15% alkohola
2009.	Pjenušava vina od svježā grožđa s volumnim udjelom stvarnog alkohola od $\leq$ 8.5%
	Bijela vina iz određenih geografskih područja (kvalitetna vina proizvedena u posebnim regijama)
	Bijela vina (ostala), koja nisu kvalitetna vina proizvedena u posebnim regijama
	Vina i mošt, spriječene ili zaustavljene fermentacije dodavanjem alkohola u otopini s CO <sub>2</sub> , tlaka $\geq$
	Kvalitetna vina i mošt spriječene ili zaustavljene fermentacije dodavanjem alkohola, kvalitetna vina
	Vina i mošt spriječene ili zaustavljene fermentacije dodavanjem alkohola, alkoholne jakosti $\leq$ 15%
	Port, Madeira, Sherry i ostala vina s $>$ 15% alkohola
2010.	Pjenušava vina od svježā grožđa ( isključujući šampanjac; trošarine na alkohona pića)
	Bijela vina iz određenih geografskih područja (kvalitetna vina proizvedena u posebnim regijama)
	Vina i mošt, spriječene ili zaustavljene fermentacije dodavanjem alkohola u otopini s CO <sub>2</sub> , tlaka $\geq$
	Kvalitetna vina i mošt spriječene ili zaustavljene fermentacije dodavanjem alkohola, kvalitetna vina
	Vina i mošt spriječene ili zaustavljene fermentacije dodavanjem alkohola, alkoholne jakosti $\leq$ 15% (
	Port, Madeira, Sherry i ostala vina s $>$ 15% alkohola
2011.	Pjenušava vina od svježā grožđa (isključujući šampanjac, trošarine na alkoholna pića)
	Bijela vina iz određenih geografskih područja (kvalitetna vina proizvedena u posebnim regijama)
	Kvalitetna vina i mošt spriječene ili zaustavljene fermentacije dodavanjem alkohola, kvalitetna vina
	Vina i mošt spriječene ili zaustavljene fermentacije dodavanjem alkohola, alkoholne jakosti $\leq$ 15% (
	Port, Madeira, Sherry i ostala vina s $>$ 15% alkohola
2012.	Pjenušava vina od svježā grožđa (isključujući šampanjac, trošarine na alkoholna pića)
	Bijelo vino s zaštićenom oznakom izvornosti (ZOI)
	Kvalitetna vina i mošt spriječene ili zaustavljene fermentacije dodavanjem alkohola, s zaštićenom oz
	Vina i mošt spriječene ili zaustavljene fermentacije dodavanjem alkohola, alkoholne jakosti $\leq$ 15%
	Port, Madeira, Sherry i ostala vina s $>$ 15% alkohola
2013.	Pjenušava vina od svježā grožđa (isključujući šampanjac, trošarine na alkoholna pića)

	Bijelo vino s zaštićenom oznakom izvornosti (ZOI)
	Vina i mošt, čija je fermentacija spriječena ili zaustavljena dodatkom alkohola u otopini s CO <sub>2</sub> , tla
	Kvalitetna vina i mošt čija je fermentacija spriječena ili zaustavljena fermentacije dodatkom alkohola
	Vina i mošt čija je fermentacija spriječena ili zaustavljena dodatkom alkohola, sa sadržajem alkohol
	Port, Madeira, Sherry i ostala vina s > 15% alkohola
2014.	Pjenušava vina od svježeg grožđa (isključujući šampanjac; trošarine na alkoholna pića)
	Bijelo vino sa zaštićenom oznakom izvornosti (ZOI)
	Vina i mošt, čija je fermentacija spriječena ili zaustavljena dodatkom alkohola u otopini s CO <sub>2</sub> , tla
	Kvalitetna vina i mošt čija je fermentacija spriječena ili zaustavljena fermentacije dodatkom alkohola
	Vina i mošt čija je fermentacija spriječena ili zaustavljena dodatkom alkohola, sa sadržajem alkohol
	Port, Madeira, Sherry i ostala vina s > 15 % alkohola
2015.	Pjenušava vina od svježeg grožđa (isključujući šampanjac; trošarine na alkoholna pića)
	Bijelo vino sa zaštićenom oznakom izvornosti (ZOI)
	Vina i mošt, čija je fermentacija spriječena ili zaustavljena dodatkom alkohola u otopini s CO <sub>2</sub> , tla
	Kvalitetna vina i mošt čija je fermentacija spriječena ili zaustavljena fermentacije dodatkom alkohola
	Vina i mošt čija je fermentacija spriječena ili zaustavljena dodatkom alkohola, sa sadržajem alkohol
	Port, Madeira, Sherry i ostala vina s > 15 % alkohola

Izvor: Državni zavod za statistiku Republike Hrvatske

Prilog PEST analiza

Prilog 4: Konačne zalihe vodećih zemalja u Europi (1.000 hl)

Opis	2005.	2007.	2009.	2011.	2013.	2015.	Indeks 2015./2005.
Francuska	60.607	56.793	53.626	54.236	53.135	50.317	83,02
Španjolska	37.565	33.817	34.373	32.957	27.901	32.107	85,47
Njemačka	13.163	12.264	12.928	11.047	11.488	12.594	95,68
Portugal	10.481	10.198	9.251	9.492	7.808	8.867	84,60
Italija	43.383	41.121	44.748	41.502	:	:	

Izvor: Eurostat, 2005. - 2015., obrada autora

Prilog 5: Ukupna domaća potrošnja vodećih zemalja u Europi (1.000 hl)

Opis	2005.	2007.	2009.	2011.	2013.	2015.	Indeks 2015./2005.
Francuska	40.824	44.705	39.415	36.448	37.006	37.300	91,37
Italija	34.104	33.101	25.858	24.727	:	:	
Njemačka	20.131	20.701	20.450	20.147	20.687	19.038	94,57
Španjolska	26.032	23.920	20.992	17.010	16.235	16.609	63,80
Portugal	5.740	5.666	4.977	5.450	4.547	5.411	94,27
Rumunjska	5.927	5.333	5.404	3.976	3.583	4.087	68,96
Nizozemska	3.161	2.727	3.074	3.089	3.442	3.442	108,89

Izvor: Eurostat, 2005. - 2015., obrada autora

Prilog 6: Stupanj samodostatnosti (%)

Opis	2005.	2007.	2009.	Indeks 2009./2005.
Italija	155,80	149,94	178,84	114,79
Španjolska	165,83	160,08	171,08	103,17
Bugarska	210,41	303,98	152,12	72,30
Mađarska	131,12	93,44	146,02	111,37
Grčka	114,83	100,12	129,62	112,88
Austrija	108,45	81,71	118,69	109,45
Francuska	140,57	116,60	108,22	76,99

Izvor: Eurostat, 2005. - 2015., obrada autora

Prilog 7: Ukupna potrošnja vina po stanovniku (l/po stanovniku)

Opis	2005.	2007.	2009.	2011.	2013.	2015.	Indeks 2015./2005.
Luksemburg	61,09	66,97	57,38	51,30	53,62	50,45	82,58
Portugal	46,71	42,95	43,07	45,45	39,75	47,96	102,69
Francuska	46,95	47,70	48,06	41,28	41,96	40,74	86,79
Slovenija	43,38	39,44	36,93	37,72	37,50	37,18	85,71
Italija	46,72	40,63	32,38	32,28	33,83	35,81	76,66

Izvor: Eurostat, 2005. - 2015., obrada autora

Prilog 8: Bilanca vina u 000 hl

Opis	2004. /2005.	2005. /2006.	2006. /2007.	2007. /2008.	2008. /2009.	2009. /2010.	2010. /2011.	2011. /2012.	2012. /2013.	2013. /2014.	2014. /2015.
1. Resursi = Potrošnja*	1.707	1.776	1.725	2.110	2.383	2.630	2.617	2.604	2.490	2.133	1.869
1.1. Proizvodnja	1.204	1.248	1.237	1.365	1.278	1.424	1.433	1.409	1.293	1.249	842
1.2. Ukupan uvoz	134	144	156	141	135	148	146	145	158	201	262
1.2.1. od čega uvoz iz država izvan EU-a	114	125	130	132	127	130	128	131	142	142	16
1.2.2. od čega uvoz flaširanih vina	-	-	-	-	-	-	-	-	26	58	12
1.3. Početne zalihe	369	383	332	603	971	1.058	1.038	1.050	1.039	683	765
2. Potrošnja = Resursi**	1.707	1.776	1.725	2.110	2.383	2.630	2.617	2.604	2.490	2.133	1.869
2.1. Ukupan izvoz	29	30	30	26	26	24	38	58	53	32	42
2.1.1. od čega izvoz u države izvan EU-a	14	16	18	16	16	15	27	19	20	16	18
2.1.2. od čega izvoz flaširanih vina	-	-	-	-	-	-	-	-	19	16	18
2.2. Ukupna domaća potrošnja	1.295	1.414	1.092	1.113	1.300	1.568	1.529	1.507	1.754	1.335	1.159
2.2.1. Potrošnja za ljudsku prehranu (bruto)	1.075	1.216	932	952	1.062	1.296	1.220	1.326	1.655	1.241	1.086
2.2.2. Industrijska potrošnja	209	185	150	150	224	257	293	169	78	80	61
2.2.3. Gubici	12	13	10	11	13	16	15	12	21	13	12
2.3. Konačne zalihe	383	332	603	971	1.058	1.038	1.050	1.039	683	765	669
3. Stupanj samodostatnosti (%)	93	88	113	123	98	91	94	93	74	94	73
4. Potrošnja za ljudsku prehranu po glavi stanovnika (bruto) (l)	24	27	21	21	24	29	29	31	39	29	26

\*Potrošnja (1.1. + 1.2. + 1.3.), \*\*Resursi (2.1. + 2.2. + 2.3.)

Izvor: Državni zavod za statistiku Republike Hrvatske, 2015.



Prilog SWOT analiza

Prilog 9: Snage vinarija i vinarstva Republike Hrvatske

Grupe	Varijabla	Srednja vrijednost	Medijan	Mod	Standardna devijacija	Varijanca
Turizam	Turizam	4,20	5,00	5,00	1,00	1,00
Prirodni resursi	Vrhunski položaji za uzgoj visokokvalitetnog grožđa	4,12	4,00	4,00	0,83	0,69
	Okolišni uvjeti za vinogradarsku proizvodnju	4,00	4,00	5,00	1,15	1,33
	Autohtone sorte vinove loze	3,80	4,00	4,00	0,87	0,75
	Mogućnosti razvoja ekološkog vinogradarstva	3,48	3,00	3,00	0,87	0,76
Know how	Tradicija bavljenja uzgojem vinove loze	3,68	4,00	3,00	0,95	0,89
	Veći broj školovanih enologa - baza stručnjaka u proizvodnji	3,32	3,00	3,00	0,90	0,81
Tržište	Povjerenje potrošača	3,48	4,00	4,00	0,92	0,84
	Tržna pozicija i imidž vinorodnog područja na domaćem tržištu	3,32	3,00	4,00	0,95	0,89

Prilog 10: Slabosti vinarija i vinarstva Republike Hrvatske

Grupe	Varijabla	Srednja vrijednost	Medijan	Mod	Standardna devijacija	Varijanca
Tehnologija	Male usitnjene površine	4,20	5,00	5,00	1,15	1,33
	Mali broj površina pod navodnjavanjem	3,52	4,00	4,00	1,16	1,34
	Otežana ili nemoguća primjena suvremene tehnologije	3,24	3,00	3,00	1,09	1,19
	Zastarjela tehnologiju	3,24	3,00	3,00	0,88	0,77
	Stari vinogradi u lošoj kondiciji	3,16	3,00	3,00	0,99	0,97
	Orijentiranost na prinos	2,92	3,00	3,00	0,95	0,91
Ljudski resursi	Neorganiziranost vinogradara	4,20	4,00	5,00	0,91	0,83
	Problem radne snage	3,96	4,00	4,00	0,84	0,71
	Slaba informiranost i poduzetničke vještine	3,84	4,00	4,00	0,80	0,64
	Manjak stručne pomoći i visoke cijene konzaltinga	2,88	3,00	3,00	0,97	0,94
Tržište	Nedostatak marketinga vina	4,20	4,00	4,00	0,82	0,67
	Cjenovna ne konkurentnost	4,12	4,00	4,00	0,78	0,61
	Sivo/crno tržište, šverc grožđa i vina	3,92	4,00	4,00	0,95	0,91
	Problemi u plasmanu vina u ugostiteljstvu	3,64	4,00	4,00	1,15	1,32
	Zalihe vina	3,44	3,00	3,00	0,92	0,84
	Niske cijene za prodaju vina u rinfuzi	2,60	3,00	3,00	0,87	0,75
Izvori financiranja (Male potpore za otežane uvjete gospodarenja)	Male potpore za otežane uvjete gospodarenja	2,80	3,00	3,00	1,12	1,25
Državna administracija	Skupa i složena birokracija	3,96	4,00	5,00	0,93	0,87

Prilog 11: Prilike za vinarije i vinarstvo Republike Hrvatske

Grupe	Varijabla	Srednja vrijednost	Medijan	Mod	Standardna devijacija	Varijanca
Nove tehnologije	Nove tehnologije	2,00	2,00	1,00a	0,96	0,92
Tržište	Novi oblici prodaje - Web prodaja	3,04	3,00	4,00	1,17	1,37
	Regulacija tržišta vina u EU	2,84	3,00	3,00	0,69	0,47
	Razvoj tržišta/dolazak novih vinskih poduzetnika	2,72	3,00	3,00	1,02	1,04
	Povećanje tržišta – ulazak u EU	2,56	2,00	2,00	1,16	1,34
	Veći protok ideja, ljudi i kapitala	2,56	2,00	2,00	1,08	1,17
	Porast potražnje za posebnim vinima (vrhunska kakvoća, autohtone sorte, ekološka proizvodnja)	2,16	2,00	2,00	0,85	0,72
Turizam	Razvoj elitnog turizma	2,64	3,00	3,00a	1,11	1,24
	Porast turističke potražnje	2,16	2,00	2,00	1,18	1,39
	Razvoj agroturizma i vinskog turizma	2,04	2,00	1,00	1,27	1,62
EU - ruralni razvoj	Obveza planiranja ruralnog razvoja	2,56	3,00	2,00a	0,92	0,84
	EU programi za ruralni prostor, očuvanje tradicionalnih gospodarskih aktivnosti i očuvanje bioraznolikosti	2,44	2,00	2,00	0,92	0,84
Ekologija i održivi razvoj	Važnost ekološkog uzgoja	3,04	3,00	3,00	0,73	0,54
	Rast svijesti o nužnosti održivog razvoja i očuvanju tradicijskog, kulturnog i povijesnog nasljeđa;	2,36	2,00	2,00	1,04	1,07

Prilog 12: Prijetnje vinarijama i vinarstvu Republike Hrvatske

Grupe	Varijabla	Srednja vrijednost	Medijan	Mod	Standardna devijacija	Varijanca
Tehnologija	Promjena strukture i teksture tla upotrebom teške mehanizacije	3,56	4,00	4,00	0,77	0,59
	Zaštita od bolesti i štetnika	3,20	3,00	3,00	1,08	1,17
	Klimatske promjene, problem navodnjavanja	2,88	3,00	3,00	0,93	0,86
Ljudski resursi	Manjak motivacije za vinogradarstvo	3,20	3,00	3,00	0,96	0,92
Tržište	Preferencije tržišta/drugi tip vina	3,24	3,00	3,00	1,13	1,27
	Koncentracija vinske industrije	2,96	3,00	3,00	1,06	1,12
	Gubitak identiteta kroz globalizacijske procese	2,96	3,00	3,00	1,31	1,71
	Daljnje jačanje trgovačkih lanaca	2,92	3,00	3,00	1,04	1,08
	Kriza u zadrugarstvu	2,68	3,00	3,00	1,35	1,81
	Uvoz jeftinog grožđa i vina	2,48	2,00	2,00	1,19	1,43
	Pad cijena vina i grožđa	2,48	2,00	2,00	1,08	1,18
	Gospodarska kriza i pad kupovne moći domaćeg stanovništva	2,32	2,00	2,00	1,18	1,39
	Gospodarska kriza i pad potražnje vina	2,28	2,00	2,00	1,14	1,29
	Neplaćanje i nelikvidnost	2,28	2,00	1,00	1,40	1,96
	Ponuda jednako kvalitetnih vina po nižim cijenama	2,20	2,00	1,00	1,38	1,92
Masovni turizam, onečišćenje okoliša	Masovni turizam, onečišćenje okoliša,	3,40	4,00	4,00	0,91	0,83
Državna administracija	Nesređeno vlasništvo nad nekretninama	2,64	2,00	2,00	1,04	1,07
	Nesređeno i komplicirano zakonodavstvo	2,56	2,00	2,00	1,26	1,59
	Ukidanje carina prema EU i smanjenje carina prema „novim“ vinskim zemljama	2,48	2,00	2,00	1,08	1,18
	Crno tržište i odsustvo inspekcijskog nadzora	2,16	2,00	2,00	1,14	1,31

Prilog 13: Usporedba srednje vrijednosti (Mean) i 5% Trimmed Mean vrijednosti snaga, slabosti, prilika i prijetnji vinarijama i vinarstvu (n = 25)

Varijabla	Vrijednost	Statistic
Okolišni uvjeti za vinogradarsku proizvodnju	Mean	4,00
	5% Trimmed Mean	4,11
Vrhunskih položaji za uzgoj visokokvalitetnog grožđa	Mean	4,12
	5% Trimmed Mean	4,18
Autohtone sorte vinove loze	Mean	3,80
	5% Trimmed Mean	3,83
Mogućnosti razvoja ekološkog vinogradarstva	Mean	3,48
	5% Trimmed Mean	3,48
Tradicija bavljenja uzgojem vinove loze	Mean	3,68
	5% Trimmed Mean	3,70
Tržna pozicija i imidž vinorodnog područja na domaćem tržištu	Mean	3,32
	5% Trimmed Mean	3,37
Povjerenje potrošača	Mean	3,48
	5% Trimmed Mean	3,48
Turizam	Mean	4,20
	5% Trimmed Mean	4,28
Veći broj školovanih enologa - baza stručnjaka u proizvodnji	Mean	3,32
	5% Trimmed Mean	3,30

Stari vinogradi u lošoj kondiciji	Mean	3,16
	5% Trimmed Mean	3,18
Male usitnjene površine	Mean	4,20
	5% Trimmed Mean	4,32
Mali broj površina pod navodnjavanjem	Mean	3,52
	5% Trimmed Mean	3,57
Otežana ili nemoguća primjena suvremene tehnologije	Mean	3,24
	5% Trimmed Mean	3,27
Zastarjela tehnologiju	Mean	3,24
	5% Trimmed Mean	3,27
Orijentiranost na prinos	Mean	2,92
	5% Trimmed Mean	2,92
Male potpore za otežane uvjete gospodarenja	Mean	2,80
	5% Trimmed Mean	2,78
Problem radne snage	Mean	3,96
	5% Trimmed Mean	4,04
Neorganiziranost vinogradara	Mean	4,20
	5% Trimmed Mean	4,27
Slaba informiranost i poduzetničke vještine	Mean	3,84
	5% Trimmed Mean	3,88
Cjenovna ne konkurentnost	Mean	4,12
	5% Trimmed Mean	4,18

Zalihe vina	Mean	3,44
	5% Trimmed Mean	3,43
Nedostatak marketinga vina	Mean	4,20
	5% Trimmed Mean	4,27
Niske cijene za prodaju vina u rinfuzi	Mean	2,60
	5% Trimmed Mean	2,57
Sivo/crno tržište, šverc grožđa i vina	Mean	3,92
	5% Trimmed Mean	3,97
Problemi u plasmanu vina u ugostiteljstvu	Mean	3,64
	5% Trimmed Mean	3,71
Skupa i složena birokracija	Mean	3,96
	5% Trimmed Mean	4,00
Manjak stručne pomoći i visoke cijene konzaltinga	Mean	2,88
	5% Trimmed Mean	2,92
Nove tehnologije	Mean	2,00
	5% Trimmed Mean	1,94
Važnost ekološkog uzgoja	Mean	3,04
	5% Trimmed Mean	3,04
Rast svijesti o nužnosti održivog razvoja i očuvanju tradicijskog, kulturnog i povijesnog nasljeđa;	Mean	2,36
	5% Trimmed Mean	2,30
Regulacija tržišta vina u EU	Mean	2,84

	5% Trimmed Mean	2,82
Povećanje tržišta – ulazak u EU	Mean	2,56
	5% Trimmed Mean	2,52
Veći protok ideja, ljudi i kapitala	Mean	2,56
	5% Trimmed Mean	2,52
Porast potražnje za posebnim vinima (vrhunska kakvoća, autohtone sorte, ekološka proizvodnja)	Mean	2,16
	5% Trimmed Mean	2,12
Razvoj tržišta/dolazak novih vinskih poduzetnika	Mean	2,72
	5% Trimmed Mean	2,70
Porast turističke potražnje	Mean	2,16
	5% Trimmed Mean	2,07
Razvoj elitnog turizma	Mean	2,64
	5% Trimmed Mean	2,66
Razvoj agroturizma i vinskog turizma	Mean	2,04
	5% Trimmed Mean	1,93
Obveza planiranja ruralnog razvoja	Mean	2,56
	5% Trimmed Mean	2,57
EU programi za ruralni prostor, očuvanje tradicionalnih gospodarskih aktivnosti i očuvanje bioraznolikosti	Mean	2,44
	5% Trimmed Mean	2,43
Novi oblici prodaje - Web prodaja	Mean	3,04
	5% Trimmed Mean	3,06

Promjena strukture i teksture tla upotrebom teške mehanizacije	Mean	3,56
	5% Trimmed	
	Mean	3,57
Klimatske promjene, problem navodnjavanja	Mean	2,88
	5% Trimmed	
	Mean	2,92
Zaštita od bolesti i štetnika	Mean	3,20
	5% Trimmed	
	Mean	3,21
Uvoz jeftinog grožđa i vina	Mean	2,48
	5% Trimmed	
	Mean	2,42
Pad cijena vina i grožđa	Mean	2,48
	5% Trimmed	
	Mean	2,42
Ponuda jednako kvalitetnih vina po nižim cijenama	Mean	2,20
	5% Trimmed	
	Mean	2,11
Gospodarska kriza i pad potražnje vina	Mean	2,28
	5% Trimmed	
	Mean	2,21
Gospodarska kriza i pad kupovne moći domaćeg stanovništva	Mean	2,32
	5% Trimmed	
	Mean	2,24
Ukidanje carina prema EU i smanjenje carina prema „novim“ vinskiim zemljama	Mean	2,48
	5% Trimmed	
	Mean	2,43
Preferencije tržišta/drugi tip vina	Mean	3,24
	5% Trimmed	
	Mean	3,27
Koncentracija vinske industrije	Mean	2,96
	5% Trimmed	
	Mean	2,96

Daljnje jačanje trgovačkih lanaca	Mean	2,92
	5% Trimmed	
	Mean	2,92
Manjak motivacije za vinogradarstvo	Mean	3,20
	5% Trimmed	
	Mean	3,21
Kriza u zadrugarstvu	Mean	2,68
	5% Trimmed	
	Mean	2,64
Neplaćanje i nelikvidnost	Mean	2,28
	5% Trimmed	
	Mean	2,20
Crno tržište i odsustvo inspekcijskog nadzora	Mean	2,16
	5% Trimmed	
	Mean	2,07
Nesređeno i komplicirano zakonodavstvo	Mean	2,56
	5% Trimmed	
	Mean	2,51
Masovni turizam, onečišćenje okoliša,	Mean	3,40
	5% Trimmed	
	Mean	3,39
Nesređeno vlasništvo nad nekretninama	Mean	2,64
	5% Trimmed	
	Mean	2,60
Gubitak identiteta kroz globalizacijske procese	Mean	2,96
	5% Trimmed	
	Mean	2,96

Prilog 14: I dio tablice korelacije (Pearsonovog koeficijenta korelacije) snaga i slabosti vinarija i vinarstva RH (n = 25)

Korelacija c	Okoliš	Vrhunski položaji	Autohtone sorte	Ekologija	Tradicija	Tržna pozicija i imidž	Povjerenje potrošača	Turizam	Školovani enolozi	Stari vinogradi	Male površine	Mali broj navodnjavanih površina	Otežana primjena tehnologije
Okoliš	1												
Vrhunskih položaji	-,043	1											
Autohtone sorte	,042	,497*	1										
Ekologija	,083	-,197	,022	1									
Tradicija	-,344	-,108	-,183	,194	1								
Tržna pozicija i imidž	-,038	,161	,031	-,042	,399*	1							
Povjerenje potrošača	,039	-,133	,073	,117	,280	,584**	1						
Turizam	,072	,620**	,289	-,115	-,062	,062	-,109	1					
Školovani enolozi	-,120	-,053	,086	,115	,027	-,076	-,042	,343	1				
Stari vinogradi	-,183	-,329	-,156	,101	-,077	-,504*	-,456*	-,076	,081	1			
Male površine	-,219	,017	-,208	-,017	-,015	-,290	-,605**	,217	,096	,483*	1		
Mali broj navodnjavanih površina	-,374	-,154	-,224	,073	,501*	-,196	-,166	-,093	-,046	,544**	,479*	1	
Otežana primjena tehnologije	-,430*	,196	-,035	,049	,360	,003	-,161	,413*	,300	,273	,456*	,490*	1

\* Korelacija je značajna na razini 0.05 (2-tailed). \*\*. Korelacija je značajna na razini 0.01 (2-tailed).c. Lista n = 25



Prilog 15: II dio tablice korelacije (Pearsonovog koeficijenta korelacije) snaga i slabosti vinarija i vinarstva RH (n = 25)

Korelacija c	Zastarjela tehnologija	Orijentiranost na prinos	Male potpore za OUG	Radna snaga	Neorganiziranost	Slaba informiranost i poduzetničke vještine	Cjenovna nekonkurentnost	Zalihe vina	Nedostatak marketinga vina	Niske cijene rinfuze	Sivo/crno tržište	Problemi plasmana vina u ugostiteljstvu	Administracija	Manjak stručne pomoći i visoke cijene konzaltinga
Zastarjela tehnologija	1													
Orijentiranost na prinos	-0,125	1												
Male potpore za OUG	,475*	0,063	1											
Radna snaga	-0,099	0,152	0,301	1										
Neorganiziranost	0,353	0,211	0,163	0,065	1									
Slaba informiranost i poduzetničke vještine	-0,062	0,256	0,056	-0,01	,445*	1								
Cjenovna nekonkurentnost	0,26	,461*	-0,115	0,008	,608**	0,299	1							
Zalihe vina	0,07	0,137	0,333	0,078	0,09	0,214	0,156	1						
Nedostatak marketinga vina	0,162	0,182	,411*	0,134	0,224	0,242	0,287	0,323	1					
Niske cijene rinfuze	0,35	0,061	0,301	-0,08	0	0,385	0,012	,493*	0,059	1				
Sivo/crno tržište	0,322	0,359	0,18	0,152	0,019	-0,127	0,181	0,09	0,235	0,262	1			
Problemi plasmana vina u ugostiteljstvu	0,089	0,276	0,266	-0,059	-0,206	0,206	-0,043	-0,002	,435*	0,309	0,314	1		
Administracija	0,164	0,183	,471*	0,104	0,254	0,27	-0,107	0,119	0,229	0,134	0,09	0,141	1	
Manjak stručne pomoći i visoke cijene konzaltinga	0,328	,574**	0,361	-0,057	0,028	0,028	0,13	0,202	0,242	0,337	,439*	0,295	0,316	1

\*. Korelacija je značajna na razini 0.05 (2-tailed). \*\*. Korelacija je značajna na razini 0.01 (2-tailed). c. Lista n = 25

Prilog 16: I dio tablice korelacije (Pearsonovog koeficijenta korelacije) prilika i prijetnji vinarijama i vinarstvu RH (n = 25)


Korelacija c	Nove tehnologije	Važnost ekološkog uzgoja	Svijest o nužnosti održivog razvoja...	Regulacija tržišta vina u EU	Povećanje tržišta – ulazak u EU	Veći protok ideja, ljudi i kapitala	Porast potražnje za „posebnim” vinima	Razvoj tržišta...	Porast turističke potražnje	Razvoj elitnog turizma	Razvoj agroturizma i vinskog turizma	Obveza planiranja ruralnog razvoja	EU programi za ruralni prostor...	Novi oblici prodaje – web prodaja	Promjena strukture i tekture tla...	Klimatske promjene, problem navodnjavanja	Zaštita od bolesti i štetnika
Nove tehnologije	1																
Važnost ekološkog uzgoja	0,178	1															
Svijest o nužnosti održivog razvoja...	0	0,144	1														
Regulacija tržišta vina u EU	0,253	0,013	0,376	1													
Povećanje tržišta – ulazak u EU	,414*	0,071	0,138	,483*	1												
Veći protok ideja, ljudi i kapitala	0,241	0,128	,518**	,573**	,570**	1											
Porast potražnje za „posebnim” vinima	,409*	0,056	,452*	,544**	,540**	,622**	1										
Razvoj tržišta...	0,085	-0,151	0,296	0,23	0,209	,449*	,485*	1									
Porast turističke potražnje	0,369	-0,008	0,19	,495*	,603**	,677**	,597**	0,177	1								
Razvoj elitnog turizma	0,195	0,069	-0,064	0,357	,486*	,450*	0,327	0,164	,585**	1							
Razvoj agroturizma i vinskog turizma	,444*	0,31	0,21	,578**	,606**	,587**	,532**	-0,055	,828**	,451*	1						
Obveza planiranja ruralnog razvoja	0	-0,035	0,042	,544**	0,203	0,175	0,148	-0,093	0,338	0,083	,551**	1					
EU programi za ruralni prostor...	0,332	0,158	0,09	,579**	,583**	0,371	0,387	0,182	,511**	0,243	,627**	,488*	1				
Novi oblici prodaje – web prodaja	0,037	-0,05	-0,081	0,318	0,106	0,113	0,035	0,114	-0,035	-0,18	0,027	,405*	0,332	1			
Promjena strukture i tekture tla...	-0,34	0,106	0,312	0,019	-,461*	0,008	0,112	0,314	-0,333	-0,193	-0,322	-0,109	-0,187	0,252	1		
Klimatske promjene, problem navodnjavanja	0,328	-0,054	0,134	0,165	-0,129	0,111	0,29	0,227	0,323	0,118	0,216	0,033	0,065	0,158	0,274	1	
Zaštita od bolesti i štetnika	0,242	0,199	0,194	0,325	0,14	0,328	0,281	,468*	0,072	0,062	0,085	0,219	0,16	0,388	0,261	0,316	1

\*. Korelacija je značajna na razini 0.05 (2-tailed). \*\*. Korelacija je značajna na razini 0.01 (2-tailed). c. Lista n = 25. Napomena: U tablici su naznačeni skraćeni nazivi prilika i prijetnji vinarijama. Detaljni rezultati statističke obrade dostupni na zahtjev autorici.

Prilog 17: II dio tablice korelacije (Pearsonovog koeficijenta korelacije) prilika i prijetnji vinarijama i vinarstvu RH (n = 25)


Korelacija c	Uvoz jeftinog grožđa i vina	Pad cijena vina i grožđa	Kvalitetna vina po nižim cijenama	Gospodarska kriza i pad potražnje vina	Gospodarska kriza i pad kupovne moći	Ukidanje i smanjenje carina...	Preferencije tržišta	Koncentracija vinske industrije	Jačanje trgovačkih lanaca	Manjak motivacije za vinogradarstvo	Kriza u zadrugarstvu	Neplaćanje i nelikvidnost	Crno tržište i odsustvo inspekcijskog nadzora	...zakonodavstvo	Masovni turizam...	Nesređeno vlasništvo...	Gubitak identiteta...
Uvoz jeftinog grožđa i vina	1																
Pad cijena vina i grožđa	,683**	1															
Kvalitetna vina po nižim cijenama	0,343	0,239	1														
Gospodarska kriza i pad potražnje vina	,449*	,494*	,466*	1													
Gospodarska kriza i pad kupovne moći	,537**	,591**	,520**	,862**	1												
Ukidanje i smanjenje carina...	0,394	,433*	,627**	,562**	,558**	1											
Preferencije tržišta	-0,151	0,106	-0,192	0,01	-0,185	0,14	1										
Koncentracija vinske industrije	0,213	0,307	0,148	0,148	0,111	,489*	,496*	1									
Jačanje trgovačkih lanaca	0,335	0,258	0,128	0,338	0,294	,443*	0,195	,452*	1								
Manjak motivacije za vinogradarstvo	0,168	0,225	0,157	0,367	,457*	0,225	-0,123	0,172	0,059	1							
Kriza u zadrugarstvu	-0,108	-0,176	0,237	0,224	0,277	0,081	-0,386	0,078	-0,049	,505*	1						
Neplaćanje i nelikvidnost	,440*	0,292	,744**	,629**	,700**	,457*	-0,361	0,008	0,188	0,174	0,249	1					
Crno tržište i odsustvo inspekcijskog nadzora	0,155	0,103	,479*	,445*	0,362	,406*	-0,031	0,143	0,187	0,084	,549**	,570**	1				
...zakonodavstvo	0,091	-0,022	0,148	0,148	0,155	-0,083	0,019	0,017	0,195	0,11	,478*	0,285	,629**	1			
Masovni turizam...	0,084	0,303	-0,165	0,088	-0,085	0,303	,510**	,405*	0,035	0,143	-0,061	-0,189	0,256	0,014	1		
Nesređeno vlasništvo...	0,078	-0,285	0,198	0,089	-0,106	0,012	-0,137	-0,127	-0,028	0,076	0,273	0,331	,508**	0,384	0,115	1	
Gubitak identiteta...	0,307	0,338	0,005	,400*	0,333	,396*	0,261	,510**	0,182	0,207	0,064	0,006	0,116	-0,062	,503*	-0,196	1

\*. Korelacija je značajna na razini 0.05 (2-tailed). \*\*. Korelacija je značajna na razini 0.01 (2-tailed). c. Lista n = 25. Napomena: U tablici su naznačeni skraćeni nazivi prilika i prijetnji vinarijama. Detaljni rezultati statističke obrade dostupni na zahtjev autorici.




Prilog 18: Koeficijent tekuće likvidnosti malih i srednje velikih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora




Prilog 19: Koeficijent ubrzane likvidnosti malih i srednje velikih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora




Prilog 20: Koeficijent financijske stabilnosti malih i srednje velikih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora




Prilog 21: Razina zaduženosti malih i srednje velikih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora




Prilog 22: ROA i ROE malih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 91 poslovnih subjekata)

Izvor: FINA (2016), obrada autora




Prilog 23: ROA i ROE srednje velikih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 4 poslovnih subjekata)

Izvor: FINA (2016), obrada autora




Prilog 24: Altmanov A-Z-score srednje velikih poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora




Prilog 25: Koeficijent tekuće likvidnosti poslovnih subjekata prema pravnom statusu za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora




Prilog 26: Koeficijent ubrzane likvidnosti prema pravnom statusu poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora




Prilog 27: Koeficijent financijske stabilnosti prema pravnom statusu poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora




Prilog 28: Razina zaduženosti prema pravnom statusu poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora




Prilog 29: ROA i ROE dioničkih društava za razdoblje od 2011. do 2015. (srednja vrijednost, n = 7 poslovnih subjekata)

Izvor: FINA (2016), obrada autora




Prilog 30: ROA i ROE društava ograničene odgovornosti za razdoblje od 2011. do 2015. (srednja vrijednost, n = 61 poslovnih subjekata)

Izvor: FINA (2016), obrada autora



Prilog 31: ROA i ROE poljoprivrednih zadruga za razdoblje od 2011. do 2015. (srednja vrijednost, n = 17 poslovnih subjekata)

Izvor: FINA (2016), obrada autora



Prilog 32: Altmanov A-Z-score modela prema pravnom statusu poslovnih subjekata za razdoblje od 2011. do 2015. (srednja vrijednost, n = 95 poslovnih subjekata)

Izvor: FINA (2016), obrada autora



Prilog 33: Relativni utjecaj triju nezavisnih varijabli na ukupni prihod model višestruke regresije sa standardiziranim varijablama

Scaled Coefficients

Sample: 1 95

Included observations: 95

Variable	Coefficient	Standardized Coefficient	Elasticity at Means
C	369653.2	NA	0.099298
BZ	-111089.2	<b>-0.438614</b>	-0.312487
MT	1.222366	<b>0.761621</b>	0.740964
TO	2.379972	<b>0.614260</b>	0.472224

Izvor: FINA (2016), ispis iz EViews 7.0

Prilog 34: Relativni utjecaj triju nezavisnih varijabli na ukupni prihod model višestruke regresije sa standardiziranim varijablama

Scaled Coefficients

Sample: 1 95

Included observations: 95

Variable	Coefficient	Standardized Coefficient	Elasticity at Means
C	6034622.	NA	1.621054
BZ	-88067.50	<b>-0.347717</b>	-0.247728
MT	1.308657	<b>0.815387</b>	0.793271
TO	1.313588	<b>0.339031</b>	0.260637
PS	-5735731.	<b>-0.193804</b>	-1.427234

Izvor: FINA (2016), ispis iz EViews 7.0

Prilog 35: Relativni utjecaj triju nezavisnih varijabli na ukupni prihod model višestruke regresije sa standardiziranim varijablama

Scaled Coefficients

Sample: 1 95

Included observations: 95

Variable	Coefficient	Standardized Coefficient	Elasticity at Means
C	17387248	NA	4.670660
BZ	-133662.3	<b>-0.527739</b>	-0.375983
MT	1.220551	<b>0.760491</b>	0.739864
TO	1.291021	<b>0.333207</b>	0.256159
V	-16674888	<b>-0.433109</b>	-4.290700

Izvor: FINA (2016), ispis iz EViews 7.0

Prilog 36: Regresija ukupnog prihoda (zavisne varijable) i broja zaposlenih i pravnog statusa

Dependent Variable: UP

Method: Least Squares

Sample: 1 95

Included observations: 95

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	9314389.	2163411.	4.305419	0.0000
BZ	165796.9	18374.45	9.023229	0.0000
PS	-7910791.	2147091.	-3.684423	0.0004
R-squared	0.735937	Mean dependent var		3722653.
Adjusted R-squared	0.730197	S.D. dependent var		7773032.
S.E. of regression	4037513.	Akaike info criterion		33.29123
Sum squared resid	1.50E+15	Schwarz criterion		33.37187
Log likelihood	-1578.333	Hannan-Quinn criter.		33.32381
F-statistic	128.2011	Durbin-Watson stat		1.998953
Prob(F-statistic)	0.000000			

Izvor: FINA (2016), ispis iz EViews 7.0

Prilog 37: Relativni utjecaj broja zaposlenih i pravnog statusa na ukupni prihod

Scaled Coefficients

Sample: 1 95

Included observations: 95

Variable	Coefficient	Standardized Coefficient	Elasticity at Means
C	9314389.	NA	2.502083
BZ	165796.9	<b>0.654616</b>	0.466376
PS	-7910791.	<b>-0.267297</b>	-1.968459

Izvor: FINA (2016), ispis iz EViews 7.0

Prilog 38: Regresija ukupnog prihoda (zavisne varijable) i broja zaposlenih i veličine

Dependent Variable: UP

Method: Least Squares

Sample: 1 95

Included observations: 95

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	24081143	3460796.	6.958266	0.0000
BZ	88300.31	22269.00	3.965167	0.0001
V	-22218656	3385139.	-6.563588	0.0000
R-squared	0.793617	Mean dependent var		3722653.
Adjusted R-squared	0.789130	S.D. dependent var		7773032.
S.E. of regression	3569421.	Akaike info criterion		33.04477
Sum squared resid	1.17E+15	Schwarz criterion		33.12542
Log likelihood	-1566.627	Hannan-Quinn criter.		33.07736
F-statistic	176.8862	Durbin-Watson stat		1.906215
Prob(F-statistic)	0.000000			

Izvor: FINA (2016), ispis iz EViews 7.0

Prilog 39: Relativni utjecaj broja zaposlenih i veličine na ukupni prihod

Scaled Coefficients

Sample: 1 95

Included observations: 95

Variable	Coefficient	Standardized Coefficient	Elasticity at Means
C	24081143	NA	6.468812
BZ	88300.31	<b>0.348636</b>	0.248383
V	-22218656	<b>-0.577102</b>	-5.717195

Izvor: FINA (2016), ispis iz EViews 7.0

Prilog 40: Regresija ukupnog prihoda (zavisne varijable) i ukupnih rashoda i pravnog statusa

Dependent Variable: UP

Method: Least Squares

Sample: 1 95

Included observations: 95

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	5923703.	1793271.	3.303296	0.0014
UR	0.526230	0.039833	13.21081	0.0000
PS	-4898067.	1765391.	-2.774494	0.0067
R-squared	0.828184	Mean dependent var		3722653.
Adjusted R-squared	0.824449	S.D. dependent var		7773032.
S.E. of regression	3256811.	Akaike info criterion		32.86146
Sum squared resid	9.76E+14	Schwarz criterion		32.94211
Log likelihood	-1557.920	Hannan-Quinn criter.		32.89405
F-statistic	221.7279	Durbin-Watson stat		1.961708
Prob(F-statistic)	0.000000			

Izvor: FINA (2016), ispis iz EViews 7.0

Prilog 41: Relativni utjecaj ukupnih rashoda i pravnog statusa na ukupni prihod

Scaled Coefficients

Date: 04/27/17 Time: 12:49

Sample: 1 95

Included observations: 95

Variable	Coefficient	Standardized Coefficient	Elasticity at Means
C	5923703.	NA	1.591258
UR	0.526230	<b>0.788033</b>	0.627538
PS	-4898067.	<b>-0.165500</b>	-1.218797

Izvor: FINA (2016), ispis iz EViews 7.0

Prilog 42: Regresija ukupnog prihoda (zavisne varijable) i ukupnih rashoda i veličine

Dependent Variable: UP

Method: Least Squares

Sample: 1 95

Included observations: 95

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	15425278	3157295.	4.885599	0.0000
UR	0.392953	0.053168	7.390797	0.0000
V	-14038151	3065373.	-4.579589	0.0000
R-squared	0.848373	Mean dependent var		3722653.
Adjusted R-squared	0.845077	S.D. dependent var		7773032.
S.E. of regression	3059488.	Akaike info criterion		32.73646
Sum squared resid	8.61E+14	Schwarz criterion		32.81711
Log likelihood	-1551.982	Hannan-Quinn criter.		32.76905
F-statistic	257.3760	Durbin-Watson stat		1.905914
Prob(F-statistic)	0.000000			

Izvor: FINA (2016), ispis iz EViews 7.0

Prilog 43: Relativni utjecaj ukupnih rashoda i veličine na ukupni prihod

Scaled Coefficients

Sample: 1 95

Included observations: 95

Variable	Coefficient	Standardized Coefficient	Elasticity at Means
C	15425278	NA	4.143625
UR	0.392953	<b>0.588449</b>	0.468603
V	-14038151	<b>-0.364623</b>	-3.612228

Izvor: FINA (2016), ispis iz EViews 7.0